



TUGAS AKHIR - SS 141501

**PERAMALAN NILAI TRANSAKSI JUAL BELI SAHAM DI
BURSA EFEK INDONESIA DENGAN MENGGUNAKAN
METODE ARIMAX, FUNGSI TRANSFER DAN *NEURAL
NETWORK***

**SALIS MAHFUDHOH
NRP 1313 105 008**

Dosen Pembimbing
Dr. Suhartono, M.Sc.

Program Studi S1 Statistika
Fakultas Matematika Dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2015



FINAL PROJECT - SS 141501

FORECASTING THE VALUE OF STOCK TRADING TRANSACTIONS AT INDONESIA STOCK EXCHANGE USING ARIMAX, TRANSFER FUNCTION, AND NEURAL NETWORK

SALIS MAHFUDHOH
NRP 1313 105 008

Supervisor
Dr. Suhartono, M.Sc.

Undergraduate Programme of Statistics
Faculty of Mathematics and Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2015

LEMBAR PENGESAHAN

**PERAMALAN NILAI TRANSAKSI JUAL BELI SAHAM
HARIAN DI BURSA EFEK INDONESIA DENGAN
MENGUNAKAN METODE ARIMAX, FUNGSI
TRANSFER DAN NEURAL NETWORK**

TUGAS AKHIR

**Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada**

**Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember**

Oleh :


**SALIS MAHFUDHOH
NRP. 1313 105 008**

Disetujui oleh Pembimbing Tugas Akhir :

Dr. Suhartono, M.Sc
NIP. 19710929 199512 1 001



**Mengetahui
Ketua Jurusan Statistika FMIPA-ITS**



Dr. Muhammad Mashuri, MT
NIP. 19620408 198701 1 001

SURABAYA, JULI 2015

PERAMALAN NILAI TRANSAKSI JUAL BELI SAHAM DI BURSA EFEK INDONESIA DENGAN MENGGUNAKAN METODE ARIMAX, FUNGSI TRANSFER, DAN NEURAL NETWORK

Nama Mahasiswa : Salis Mahfudhoh
NRP : 1313 105 008
Jurusan : Statistika FMIPA-ITS
Dosen Pembimbing : Dr. Suhartono, M.Sc.

Abstrak

Salah satu ukuran keberhasilan BEI dalam mengembangkan industry pasar modal adalah nilai transaksi jual beli saham setiap harinya. Ketidakpastian nilai transaksi jual beli saham ini, membuat BEI bertindak hati-hati dalam mengambil keputusan untuk menentukan target perusahaan. Oleh karena itu, tujuan penelitian ini dimaksudkan untuk memprediksi nilai transaksi saham harian serta untuk membantu BEI menentukan target dan perencanaan strategis perusahaan. Data yang digunakan dalam penelitian ini mulai periode Januari 2012 hingga Desember 2015. Metode yang digunakan adalah ARIMAX, fungsi transfer, dan neural network. Berdasarkan RMSE dan SMAPE outsample terkecil, model yang sesuai untuk prediksi nilai transaksi saham harian adalah fungsi transfer. Model ini menjelaskan bahwa prediktor yang digunakan (IHSG) berkaitan dengan nilai transaksi jual beli saham harian. Selain itu, terdapat faktor-faktor lain yang berkaitan yaitu kejadian tak terduga atau shock event (27 Agustus 2012), kebijakan peraturan baru oleh BEI (25 Maret 2013), kebijakan bursa luar negeri (18 September 2013) dan kebijakan pemerintah (31 Mei 2013).

Kata Kunci : ARIMAX, Fungsi Transfer, Neural Network, BEI (Bursa Efek Indonesia)

~Halaman ini sengaja dikoongkan~

FORECASTING THE VALUE OF STOCK TRADING TRANSACTIONS AT INDONESIA STOCK EXCHANGE USING ARIMAX, TRANSFER FUNCTION, AND NEURAL NETWORK

Name of Student : Salis Mahfudhoh
NRP : 1313 105 008
Department : Statistics FMIPA-ITS
Supervisor : Dr. Suhartono, M.Si.

Abstract

One of success measures for IDX in developing the capital market is the value of stock trading transactions every day. Due to uncertainty of stock trading value transactions, it makes IDX act prudently in making decisions to determine the targets. Therefore, goals of this research is intended to predict the value of stock transactions daily, to help IDX in determining targets and strategic planning. The data used in this study are observed from January 2012 to December 2015. The methods used are ARIMAX, transfer functions, and the neural network. Based on outsample smallest RMSE dan SMAPE, An appropriate model for the prediction of daily stock transaction value is transfer function. This model explain that the predictor (JCI) is used in connection with the value of stock trading transactions. There are other factors related are influence the unexpected events or shock event (August 27, 2012), new regulatory policies by the BEI (March 25, 2013), foreign exchange policy (September 18, 2013), government policies (May 31, 2013).

Keywords : *ARIMAX, Transfer Function, Neural Network, IDX (Indonesia Stock Exchange)*

~Halaman ini sengaja dikosongkan~

KATA PENGANTAR

Bismillahirrohmanirrohim.

Alhamdulillah, segala puji dan syukur penulis panjatkan kehadirat Allah SWT yang telah memberikan berkah, rahmat, dan hidayah-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir dengan judul.

“Peramalan Nilai Transaksi Jual Beli Saham Di Bursa Efek Indonesia Dengan Menggunakan Metode Arimax, Fungsi Transfer, Dan Neural Network ”.

Penulis menyadari bahwa dalam penyelesaian laporan Tugas Akhir ini tidak terlepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada :

1. Orang Tua dan Saudara yang selalu saya cintai dan hormati, yang telah menjadi sumber kekuatan dan semangat bagi penulis. Terimakasih atas setiap doa, perhatian, dukungan, kasih sayang, nasehat, dan semangat tiada henti kepada penulis.
2. Bapak Dr. Suhartono, M.Sc selaku dosen pembimbing yang telah memberikan waktu, bimbingan, kesabaran, motivasi, inspirasi, ilmu, saran dan banyak hal baru dalam menyelesaikan Tugas Akhir ini.
3. Bapak Dr. Drs. Agus Suharsono, M. S, dan Ibu Dra. Destri Susilaningrum, M, Si, selaku dosen penguji atas segala masukan dan arahan yang disampaikan sampai terselesaikannya Tugas Akhir ini.
4. Bapak Dr. Muhammad Mashuri, M.T, selaku Ketua Jurusan Statistika ITS.
5. Ibu Dra. Lucia Aridinanti, M.T, selaku Koordinator Program Studi Sarjana Jurusan Statistika ITS atas motivasi, dan dukungan untuk terselesaikannya Tugas Akhir.

6. Segenap dosen dan karyawan Jurusan Statistika ITS, atas ilmu, pengetahuan, motivasi, dan pengalaman selama penulis menempuh masa perkuliahan.
7. Sahabat-Sahabat yang akan selalu saya cintai dan rindukan. Terimakasih atas segala dukungan, semangat, perhatian, motivasi, kegembiraan, kebersamaan yang selalu mengu-
atkan.
8. Teman-teman seperjuangan jurusan Staistika ITS yang selalu saya cintai, terimakasih atas motivasi, semangat, dukungan, dan kebersamaannya.
9. Keluarga besar angkatan 2010 Statistika ITS, atas kesan, kebersamaan, keakraban dan pengalaman yang telah terlewati dan atas semua dukungannya.
10. Pihak-pihak lain yang telah mendukung dan membantu penyusunan Tugas Akhir ini yang tidak mungkin penulis sebutkan satu-persatu.

Penulis menyadari bahwa penyusunan Tugas Akhir ini masih jauh dari kesempurnaan. Oleh karena itu, kritik dan saran yang membangun dari semua pihak sangat diharapkan untuk tahap pengembangan selanjutnya. Besar harapan penulis bahwa informasi sekecil apapun dalam Tugas Akhir ini dapat bermanfaat bagi semua pihak.

Surabaya, 31 Juli 2015

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN.....	iii
ABSTRAK	iv
<i>ABSTRACT</i>	vi
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xiv
DAFTAR TABEL	xvi
DAFTAR LAMPIRAN	xx
 BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Perumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	6
 BAB II TINJAUAN PUSTAKA	
2.1 Statistika Deskriptif	7
2.2 <i>Time Series Analysis</i>	8
2.3 Model ARIMA	9
2.3.1 Identifikasi Model	10
2.3.2 Estimasi dan Pengujian Parameter	14
2.3.3 Pemeriksaan Diagnostik	17
2.3.4 Peramalan	18
2.4 <i>Time Series Outlier</i>	19
2.5 Model Fungsi Transfer	22
2.6 Uji <i>Lagrange Multiplier (LM)</i>	24
2.7 <i>Neural Network</i>	25
2.7.1 <i>Feedforward Neural Network</i>	26
2.7.2 Algoritma <i>Backpropagation</i>	27

2.8	Kriteria Pemilihan Model	31
2.9	Pasar Modal	31
2.10	Saham	32
 BAB III METODOLOGI PENELITIAN		
3.1	Sumber Data	35
3.2	Variabel Penelitian	35
3.2	Langkah Analisis	35
3.3	Diagram Alir Analisis.....	38
 BAB IV ANALISIS DATA DAN PEMBAHASAN		
4.1	Karakteristik Nilai Transaksi Penjualan Saham Harian Di Bursa Efek Indonesia	41
4.2	Pemodelan Nilai Transaksi Penjualan Saham Harian dengan Menggunakan Model ARIMAX (ARIMA dengan Tambahan Efek <i>Outlier</i>	50
4.2.1	Identifikasi Model pada Data Nilai Transaksi Penjualan Saham Di Bursa Efek Indonesia	50
4.2.2	Estimasi Parameter dan Uji Signifikansi Model	52
4.2.3	Pemeriksaan Diagnostik	54
4.2.4	Deteksi <i>Outlier</i>	55
4.3	Pemodelan Nilai Transaksi Penjualan Saham Harian dengan Menggunakan Model Fungsi Transfer (ARIMA dengan Tambahan Variabel Prediktor)	64
4.4	Pengujian Efek ARCH/GARCH pada Residual Model ARIMAX dan Fungsi Transfer.....	75
4.5	Pemodelan Nilai Transaksi Penjualan Saham Harian dengan Menggunakan <i>Neural Network</i>	77
 BAB V. KESIMPULAN DAN SARAN		
5.1	Kesimpulan	84

5.2 Saran.....	85
DAFTAR PUSTAKA	86
LAMPIRAN	90
BIODATA PENULIS	111

~Halaman ini sengaja dikosongkan~

DAFTAR TABEL

	Halaman
Tabel 2.1 Transformasi Box-Cox.....	11
Tabel 2.2 Identifikasi Model <i>Time Series Non Seasonal</i> Berdasarkan Plot ACF dan PACF	14
Tabel 2.3 Identifikasi Model <i>Time Series Seasonal</i> Berdasarkan Plot ACF dan PACF.....	14
Tabel 4.1 Karakteristik Nilai Transaksi Saham Harian Per Tahun (dalam Triliyun)	41
Tabel 4.2 Deskriptif Nilai Transaksi Saham Per Bulan (dalam Triliyun).....	46
Tabel 4.3 Rata-rata Nilai Transaksi Saham Per Hari di Setiap Tahun dan Per Minggu di Setiap Tahun	47
Tabel 4.4 Peristiwa yang Memberikan Nilai Transaksi Terbesar.....	49
Tabel 4.5 Peristiwa yang Memberikan Nilai Transaksi Terbesar (Lanjutan).....	50
Tabel 4.6 Hipotesis Masing-Masing Model ARIMA	53
Tabel 4.7 Uji Signifikansi Parameter Model ARIMA.....	53
Tabel 4.8 Pengujian Asumsi <i>White Noise</i> Model ARIMA	54
Tabel 4.9 Pengujian Asumsi Berdistribusi Normal Model ARIMA.....	55
Tabel 4.10 Identifikasi <i>Outlier</i> Pada Model ARIMA.....	56
Tabel 4.11 Identifikasi <i>Outlier</i> Pada Model ARIMA (Lanjutan)	57
Tabel 4.12 Ringkasan <i>Outlier</i> Pada Model ARIMA.....	57
Tabel 4.13 Uji Signifikansi Parameter Model ARIMA dengan Penambahan <i>Outlier</i>	58
Tabel 4.14 Pengujian Asumsi <i>White Noise</i> Parameter Model ARIMA dengan Penambahan <i>Outlier</i>	59
Tabel 4.15 Uji Signifikansi Parameter Model ARIMAX (4, 1, [5,11]).....	60

Tabel 4.16	Pengujian Asumsi <i>White Noise</i> Parameter Model ARIMAX (4,1,[5,11])	61
Tabel 4.17	Pengujian Asumsi Distribusi Normal Model ARIMAX.....	61
Tabel 4.18	Persamaan Model ARIMAX	62
Tabel 4.19	Nilai Kriteria Pemilihan Model ARIMAX.....	63
Tabel 4.20	Uji Signifikansi Parameter Model IHSG.....	66
Tabel 4.21	Pengujian Asumsi <i>White Noise</i> Model IHSG.....	67
Tabel 4.22	Pengujian Asumsi <i>White Noise</i> Nilai Transaksi Penjualan Saham dengan b, r, s (0, 0, 0)	68
Tabel 4.23	Uji Signifikansi Parameter Model Fungsi Transfer ARIMA ([1, 12], 0, [3, 33]) dengan b, r, s (0, 0, 0) dan Deret <i>Noise</i> ARMA (1,1)	69
Tabel 4.24	Uji <i>White Noise</i> Model Fungsi Transfer ARIMA ([1, 12], 0, [3, 33]) dengan b, r, s (0, 0, 0) dan Deret <i>Noise</i> ARMA (1,1).....	70
Tabel 4.25	Uji Signifikansi Parameter Model Fungsi Transfer ARIMA ([1, 12], 0, [3, 33]) dengan b, r, s (0, 0, 0) dan Deret <i>Noise</i> ARMA (1,1) dengan Penambahan <i>Outlier</i>	71
Tabel 4.26	Uji Signifikansi Parameter Model Fungsi Transfer ARIMA ([1, 12], 0, [3, 33]) dengan b, r, s (0, 0, 0) dan Deret <i>Noise</i> ARMA (1,1) dengan Penambahan <i>Outlier</i> (Lanjutan).....	72
Tabel 4.27	Pengujian Asumsi <i>White Noise</i> Model Fungsi Transfer dengan Penambahan <i>Outlier</i>	73
Tabel 4.28	Hasil Ramalan <i>Outsample</i> Model Fungsi Transfer .	74
Tabel 4.29	Pengujian <i>Lagrange Multiplier</i> pada Residual Model ARIMAX	76
Tabel 4.30	RMSE Model <i>Multilayer Perceptron</i> dengan <i>Input</i> Fungsi Transfer	77
Tabel 4.31	RMSE Model <i>Multilayer Perceptron</i> dengan <i>Input</i> ARIMA	79

Tabel 4.32	Nilai RMSE dan SMAPE Model-Model Peramalan Nilai Transaksi Penjualan Saham Harian.....	81
Tabel 4.33	Hasil Ramalan 1 Tahun Kedepan Model Fungsi Transfer.....	83

~Halaman ini sengaja dikosongkan~

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Arsitektur pada Model <i>Neural Network</i> dengan 1 <i>Hidden Layer</i> , 3 <i>Input Layer</i> , 4 Neuron Di <i>Hidden Layer</i> , dan 1 <i>Ouput Layer</i>	27
Gambar 3.1 Diagram Alir Analisis.....	40
Gambar 4.1 Rata-rata Nilai Transaksi Jual Beli Saham pada Tahun 2012-2014	42
Gambar 4.2 <i>Box-plot</i> Nilai Transaksi Jual Beli Saham Hari Senin-Jumat.....	44
Gambar 4.3 <i>Box-plot</i> Nilai Transaksi Jual Beli Saham Minggu 1 Hingga 5.....	45
Gambar 4.4 <i>Box-plot</i> Nilai Transaksi Jual Beli Saham Bulan Januari-Desember.....	46
Gambar 4.5 <i>Bar Chart</i> Rata-rata Nilai Transaksi Jual Beli Saham Per Minggu di Setiap Bulan	48
Gambar 4.6 <i>Time Series Plot</i> Nilai Transaksi Jual Beli Saham	49
Gambar 4.7 <i>Box-Cox Plot</i> Data Nilai Transaksi Penjualan Saham.....	51
Gambar 4.8 a. Plot ACF, b. Plot PACF	51
Gambar 4.9 a. <i>Time Series Plot</i> , b. Plot ACF, c. Plot PACF (Data Setelah Dilakukan Transformasi dan <i>Differencing</i>).....	52
Gambar 4.10 Plot Residual ARIMAX (4,1,[5]).....	60
Gambar 4.11 a. <i>Time Series Plot</i> antara <i>Fits</i> , Aktual, <i>Outsample</i> , dan <i>Forecast</i> ARIMAX (4, 1, [5, 11]), b. ARIMAX (0,1,3), c. <i>Time Series Plot</i> antara Data <i>Outsample</i> dengan Ramalan Model ARIMAX (0,1,3) dan ARIMAX (4,1,[5,11])	63
Gambar 4.12 <i>Time Series Plot</i> IHSG	64

Gambar 4.13	<i>Box Cox Plot</i> IHSG	65
Gambar 4.14	a. ACF, b. PACF	65
Gambar 4.15	a. ACF, b. PACF (Setelah <i>Differencing</i>)	66
Gambar 4.16	Plot CCf antara Nilai Transaksi Penjualan Saham dengan IHSG.....	67
Gambar 4.17	a. ACF, b. PACF Residual Nilai Transaksi Penjualan Saham dengan b, r, s (0, 0, 0).....	69
Gambar 4.18	<i>Time Series Plot</i> antara <i>Fits</i> , Aktual, <i>Outsample</i> dan Ramalan Model Fungsi Transfer	75
Gambar 4.19	Arsitektur <i>Neural Network Input</i> fungsisi Transfer (4-9-1)	78
Gambar 4.20	Arsitektur <i>Neural Network Input</i> ARIMA (4-6-1)	80
Gambar 4.21	a. <i>Time Series Plot</i> antara <i>Fits</i> dan Aktual Model <i>Neural Network</i> Fungsi Transfer dan Ramalan Model Fungsi Transfer, b. Model <i>Neural Network</i> ARIMA.....	81
Gambar 4.22	<i>Time Series Plot</i> antara <i>Fits</i> dan Nilai Ramalan Model Fungsi Transfer	82

DAFTAR LAMPIRAN

	Halaman
LAMPIRAN A. Data Nilai Transaksi Penjualan Saham Harian Periode Tahun 2012 Hingga Tahun 2014	90
LAMPIRAN B. Syntax SAS untuk Pemodelan Data Nilai Transaksi Penjualan Saham Harian	91
LAMPIRAN C. <i>Output</i> SAS untuk Pemodelan ARIMAX Data Nilai Transaksi Penjualan Saham Harian.....	98
LAMPIRAN D. <i>Output</i> SAS untuk Pemodelan Fungsi Transfer Data Nilai Transaksi Penjualan Saham Harian.....	103
LAMPIRAN E. <i>Output</i> SAS untuk Pengujian Pemodelan Kehomogenan Varians	107

~Halaman ini sengaja dikosongkan~

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam era globalisasi dewasa ini, aktivitas perdagangan saham telah menjadi hal yang lumrah bagi masyarakat luas. Keikutsertaan masyarakat dalam aktivitas perdagangan saham menunjukkan peran masyarakat untuk berinvestasi dan mendanai perusahaan sehingga tak perlu bergantung pada pinjaman asing. Dengan kata lain, masyarakat telah turut membantu dalam menyediakan modal melalui aktivitas perdagangan di pasar modal. Pasar modal yang hal ini sebagai tempat diperdagangkannya saham-saham perusahaan, dikatakan sebagai indikator kemajuan perekonomian suatu negara karena dapat menunjang ekonomi negara yang bersangkutan. Fakta bahwa pasar modal memiliki peranan penting dan pengaruh terhadap perekonomian negara telah ada dalam beberapa penelitian sejak tahun 90-an, seperti Dimirguc-Kunt dan Levine (1996), Singh (1997) serta Levine dan Zervos (1998) yang menyatakan bahwa pasar modal mempunyai hubungan yang signifikan atau berpengaruh terhadap pertumbuhan ekonomi baik dalam jangka pendek maupun jangka panjang.

Pasar modal mempunyai dua fungsi yaitu sebagai fungsi ekonomi dan fungsi keuangan. Pasar modal dikatakan sebagai fungsi ekonomi karena pasar modal menyediakan fasilitas yang mempertemukan pihak yang memiliki kelebihan dana (*investor*) dengan pihak yang memerlukan dana (*issuer*). Sedangkan pasar modal disebut sebagai fungsi keuangan karena pasar modal memberikan kemungkinan dan kesempatan memperoleh *return* (imbalan) bagi pemilik dana. Di Indonesia, bentuk fisik sekaligus pelaku dari pasar modal lebih dikenal sebagai Bursa Efek Indonesia (BEI) atau Indonesia *Stock Exchange* (IDX).

Bursa Efek Indonesia merupakan gabungan dari Bursa Efek Jakarta dan Bursa Efek Surabaya yang tergabung pada tahun 2007. Visinya adalah menjadi bursa yang kompetitif dengan

kredibilitas tingkat dunia. Untuk mencapai visinya, BEI menerapkan tata kelola perusahaan atau *corporate governance* (CG) dengan sistem yang dirancang untuk mengarahkan pengelolaan perusahaan secara profesional berdasarkan prinsip-prinsip transparansi, akuntabilitas, tanggung jawab, independen, kewajaran dan kesetaraan. Penerapan komitmen CG telah terkandung pada misi perusahaan yaitu menciptakan daya saing untuk menarik investor dan emiten melalui pemberdayaan anggota bursa dan partisipan, penciptaan nilai tambah, efisiensi biaya serta penerapan *good governance*. Dampak positif dari penerapan *good governance* dapat dikaitkan pada terciptanya akuntabilitas perusahaan, transaksi yang wajar dan independen, serta kehandalan dan peningkatan kualitas informasi kepada publik (Bursa Efek Indonesia, 2015). Oleh karenanya, Bursa Efek Indonesia dapat dikatakan memiliki peranan yang besar bagi perkembangan pasar modal di Indonesia.

Keberhasilan BEI dalam mengembangkan industri pasar modal di Indonesia akan sejalan dengan keberhasilan perekonomian negara. Hasil studi dari Divisi Riset BEI mengidentifikasi, salah satu ukuran keberhasilan BEI dalam mengembangkan industri pasar modal dapat dilihat berdasarkan besarnya nilai transaksi jual beli saham di pasar modal setiap harinya. Ketidakpastian nilai transaksi jual beli saham setiap harinya membuat pihak perusahaan harus teliti dalam menentukan target perusahaan. Sebagai acuan menentukan target, Divisi Riset BEI melakukan suatu analisis prediksi pada besarnya nilai transaksi jual beli saham untuk melihat nilai transaksi jual beli saham di periode selanjutnya. Analisis prediksi yang telah dilakukan BEI pada periode tahun 2012 dan 2013, menggunakan metode ilmu statistik yaitu ARIMA (*Autoregressive Integrated Moving Average*) dan Intervensi. Namun hasilnya menunjukkan bahwa nilai prediksi transaksi saham mempunyai selisih besar di atas nilai aktualnya. Model ARIMA diduga tidak dapat menangkap reaksi pasar modal terhadap variabel-variabel yang berpengaruh. Dengan adanya permasalahan tersebut, diperlukan metode

peramalan lain untuk melakukan analisis prediksi besarnya nilai transaksi jual beli saham di bursa efek. Adapun metode-metode peramalan lain yang dapat digunakan yaitu ARIMAX, Fungsi Transfer dan *Neural Network*.

ARIMAX merupakan gabungan antara metode ARIMA dengan faktor “X”, dimana faktor “X” digambarkan sebagai variabel *dummy* dan berupa faktor-faktor yang dapat memberikan reaksi pada pasar modal. Dalam Jogyanto (2010), pasar modal akan bereaksi pada peristiwa-peristiwa yang *surprise* atau *unexpected* dan mengandung informasi. Artinya peristiwa-peristiwa yang berpengaruh terhadap pasar modal mengandung nilai ekonomis yang dapat mengubah nilai suatu perusahaan seperti peristiwa atau pengumuman yang berhubungan dengan laba perusahaan, pengumuman industri sekuritas, pengumuman dividen, pengumuman tentang pemasaran produksi, pengumuman tentang kebijakan pemerintah, pengumuman adanya *merger* perusahaan, pengumuman adanya peraturan baru atau perubahan peraturan, pengumuman dari pemerintah seperti perubahan inflasi, tingkat suku bunga, kurs valuta asing, dan lain sebagainya. Sehingga dalam penelitian ini, akan digunakan variabel-variabel yang *surprise* atau *unexpected* sebagai dugaan yang dapat mempengaruhi nilai transaksi jual beli saham di BEI.

Banyak pembahasan yang menggunakan metode ARIMAX untuk prediksi di pasar saham. Studi mengenai model ARIMAX dapat ditemukan pada Wei (2006). Penggunaan model ARIMA sederhana banyak dilakukan pula pada kasus *financial* atau ekonometrik, salah satu referensi yang menjelaskan model ARIMA dalam kasus ini adalah Tsay (2002). Dalam suatu penelitian, model ARIMAX (Fungsi Transfer) mempunyai *error* yang lebih rendah dibandingkan dengan model *neural network* (Djojonegoro dkk, 2008). Namun pada studi yang lain, penggunaan model fungsi transfer dan *neural network* masing-masing memberikan nilai *error* yang lebih rendah untuk peramalan pendapatan pada dua kasus (Ma’rufah dkk, 2013). Selain itu, data yang di pasar modal sering disebut memiliki

volatilitas tinggi. Istilah volatilitas mengacu pada kondisi yang berkonotasi sulit diperkirakan, tidak stabil dan cenderung bervariasi. Oleh karena itu, nilai transaksi saham harian perlu dilakukan pengujian untuk melihat kondisi heteroskedastisitasnya.

Model *Neural Network* dikenal sebagai model jaringan saraf tiruan yang mengadaptasi dari struktur jaringan saraf biologis manusia. *Neural network* merupakan model regresi nonlinier yang banyak diaplikasikan pada data yang memiliki kompleksitas namun fleksibel dan tidak terbatas (Ripley, 1996). Banyak literatur yang telah membahas penggunaan model *neural network* untuk memprediksi pasar saham. Diantaranya Saad, Prokhorov dan Wunsch (1998), yang melakukan studi menggunakan *neural network* pada pasar saham, hasilnya menunjukkan bahwa model cocok pada kejadian yang ekstrim. Chen, Leung dan Daouk (2003) mengaplikasikan model *neural network* untuk prediksi indeks saham di Taiwan, diperoleh model *neural network* lebih unggul dibanding dengan model GMM (*generalized methods of moments*). Selanjutnya Mostafa (2010) menyimpulkan bahwa model *neural network* sangat berguna untuk memprediksi pergerakan bursa saham di negara berkembang, studi ini menggunakan arsitektur *multilayer perceptron* (MLP) untuk memprediksi pergerakan bursa di Kuwait. Dalam literatur Liang, Song dan Wang (2011) juga menyebutkan bahwa prosedur *neural network* dapat dipakai untuk memprediksi data yang memiliki kerumitan seperti data di pasar saham. Bhudani dkk. (2012) menyatakan bahwa model *feedforward neural network* dengan algoritma *backpropagation* merupakan alat prediksi yang konsisten dan efektif untuk prediksi pasar saham.

Meninjau dari literatur-literatur yang telah dipaparkan, penelitian ini dimaksudkan menggunakan model-model tersebut untuk memprediksi besarnya nilai transaksi saham harian di BEI. Penggunaan dari model ARIMAX, fungsi transfer, dan *neural network* dalam analisis akan dibandingkan untuk memperoleh

model yang terbaik. Model yang paling baik kemudian digunakan untuk memprediksi nilai transaksi saham harian di BEI. Hasil yang diperoleh, diharapkan dapat membantu manajemen dalam menentukan target perusahaan sekaligus sebagai bahan evaluasi dalam menentukan perencanaan strategis perusahaan.

1.2 Rumusan Masalah

Nilai transaksi jual beli saham diindikasikan sebagai salah satu ukuran keberhasilan Bursa Efek Indonesia (BEI) dalam mengembangkan industri pasar modal. Ketidakpastian nilai transaksi jual beli saham setiap harinya membuat BEI harus bertindak hati-hati dalam menentukan target perusahaan dan perencanaan strategis. BEI telah melakukan suatu analisis prediksi pada besarnya nilai transaksi jual beli saham di bursa efek. Namun, hasilnya menunjukkan bahwa prediksi nilai transaksi saham mempunyai selisih besar di atas nilai aktualnya. Oleh karena itu, penelitian ini dimaksudkan untuk melakukan analisis prediksi besarnya nilai transaksi saham dengan metode lain. Beberapa rumusan permasalahan yang digunakan dalam penelitian ini adalah :

1. Bagaimana karakteristik besarnya nilai transaksi jual beli saham harian di Bursa Efek Indonesia?
2. Bagaimana model terbaik untuk memprediksi besarnya nilai transaksi jual beli saham harian di Bursa Efek Indonesia?
3. Bagaimana hasil prediksi besarnya nilai transaksi jual beli saham harian di Bursa Efek Indonesia berdasarkan model terbaik?

1.3 Tujuan Penelitian

Sesuai rumusan permasalahan yang telah disebutkan sebelumnya, tujuan yang dapat dicapai dalam penelitian ini antara lain :

1. Mendeskripsikan karakteristik besarnya nilai transaksi jual beli saham harian di Bursa Efek Indonesia.

2. Mendapatkan model terbaik untuk memprediksi besarnya nilai transaksi jual beli harian saham di Bursa Efek Inonesia.
3. Memperoleh hasil prediksi besarnya nilai transaksi jual beli saham harian di Bursa Efek Indonesia berdasarkan model terbaik.

1.4 Manfaat Penelitian

Manfaat yang diperoleh pada penelitian ini adalah mengetahui model yang lebih baik dalam melakukan prediksi besarnya nilai transaksi jual beli saham, sekaligus membantu pihak BEI memperoleh nilai prediksi besarnya transaksi jual beli saham harian yang digunakan sebagai bahan evaluasi dalam menentukan perencanaan strategis perusahaan serta membantu manajemen dalam menentukan target perusahaan.

1.5 Batasan Masalah

Ruang lingkup pada penelitian ini dibatasi hanya pada total keseluruhan aktivitas perdagangan saham pada seluruh pasar di Bursa Efek Indonesia. Data yang digunakan merupakan besarnya nilai (jumlah rupiah) transaksi jual beli saham harian selama periode 2012 hingga 2014. Metode-metode yang digunakan untuk melakukan analisis prediksi besarnya nilai transaksi jual beli saham adalah ARIMAX (deteksi *outlier*), fungsi transfer, dan *neural network*. Dalam model *neural network*, jumlah *neuron* dalam *hidden layer* dibatasi 1 hingga 10 unit *neuron*. Prediktor yang digunakan dalam penelitian adalah IHSG.

BAB II

TINJAUAN PUSTAKA

Bab ini berisikan tentang teori-teori atau pustaka yang digunakan untuk menganalisis permasalahan dalam penelitian. Pustaka tersebut antara lain statistika deskriptif, teori dasar *time series*, model ARIMA, *time series outlier*, fungsi transfer dan *neural network*.

2.1 Statistika Deskriptif

Statistika deskriptif merupakan bagian statistika yang menguraikan metode-metode pengumpulan dan penyajian data sehingga memberikan informasi yang berguna. Statistika deskriptif sering disebut statistika deduktif yang membahas tentang bagaimana merangkum sekumpulan data dalam bentuk yang mudah dibaca dan cepat memberikan informasi yang disajikan dalam bentuk tabel, grafik, nilai pemusatan, dan nilai penyebaran. Ukuran pemusatan data adalah nilai tunggal yang mewakili suatu kumpulan dan menunjukkan karakteristik data yang meliputi *mean*, modus, dan *median*. *Mean* atau rata-rata merupakan pusat keseimbangan dari sekelompok data, hasil pembagian antara jumlah nilai setiap pengamatan dengan jumlah data pengamatan. *Mean* dirumuskan

$$\bar{Z} = \frac{\sum_{t=1}^n Z_t}{n}, \quad (2.1)$$

dengan n adalah banyak pengamatan dan Z_t merupakan pengamatan ke- t .

Ukuran penyebaran data adalah ukuran yang memberikan gambaran seberapa besar data menyebar dari titik-titik pemusatan. Salah satu ukuran penyebaran data adalah varian dan deviasi standar. Varian merupakan suatu besaran yang mengukur besarnya ragam data. Semakin besar ragam data maka nilai varian semakin besar, demikian sebaliknya. Sedangkan deviasi standar

merupakan akar dari varian. Persamaan dari varian (S^2) dan deviasi standar (S) dapat dituliskan (Walpole, 1995)

$$S^2 = \frac{1}{n-1} \sum_{t=1}^n (Z_t - \bar{Z})^2 \quad (2.2)$$

dan

$$S = \sqrt{\frac{1}{n-1} \sum_{t=1}^n (Z_t - \bar{Z})^2}. \quad (2.3)$$

Ukuran penyebaran lainnya adalah *skewness* (kemiringan) dan *kurtosis* (keruncingan). *Skewness* merupakan ukuran dari ketidaksimetrisan suatu distribusi data. *Skewness* yang bernilai nol menunjukkan bahwa distribusi data simetris. *Skewness* yang bernilai positif menyiratkan bahwa distribusi miring ke kanan, sedangkan *skewness* yang bernilai negatif menyiratkan bahwa distribusi miring ke kiri. *Kurtosis* adalah ukuran tinggi rendahnya puncak suatu distribusi data terhadap distribusi normalnya data. Jika bentuk kurva runcing berarti nilai penyebarannya kecil, sebaliknya jika bentuk kurvanya tumpul berarti nilai penyebaran besar. Rumus dari nilai *kurtosis* (Ko) dan *skewness* (Sk) ditulis sebagai berikut (Joanes dan Gill, 1998)

$$Sk = \frac{n}{(n-1)(n-2)} \sum_{t=1}^n \left(\frac{Z_t - \bar{Z}}{s} \right)^3 \quad (2.4)$$

dan

$$Ko = \left(\frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{t=1}^n \left(\frac{Z_t - \bar{Z}}{s} \right)^4 \right) - \frac{3(n-1)^2}{(n-2)(n-3)}. \quad (2.5)$$

2.2 Time Series Analysis

Bowman dan O'Connell (1993) menyatakan bahwa suatu *time series* adalah rangkaian kronologi dari suatu pengamatan atau observasi pada variabel tertentu. Sedangkan menurut Wei (2006), *time series* merupakan deretan atau rangkaian observasi

yang diambil dari waktu ke waktu dan dicatat menurut urutan waktu kejadiannya dengan interval waktu yang tetap (konstan) secara runtun. Deretan observasi tersebut dinyatakan sebagai variabel random Z_t , dimana t merupakan kumpulan indeks waktu yang menggambarkan sebuah urutan pengamatan yaitu $i = 1, 2, \dots, n$.

Sehingga deretan nilai-nilai observasi atau pengamatan dari variabel random dapat ditulis menjadi $Z_{t_1}, Z_{t_2}, \dots, Z_{t_n}$. Terdapat beberapa tujuan dari pembelajaran *time series* yakni sebagai pemahaman dan gambaran pembuatan mekanisme, peramalan nilai-nilai di masa mendatang, dan pengontrolan secara optimal pada sebuah sistem.

2.3 Model ARIMA

Menurut Makridakis dkk. (1999), terdapat beberapa model yang digunakan dalam *time series* yaitu model *Autoregressive* (AR), *Moving Average* (MA), *Mixed Autoregressive Moving Average* (ARMA), dan *Autoregressive Integrated Moving Average* (ARIMA). Model *autoregressive* merupakan model yang memperlihatkan nilai observasi Z_t bergantung pada Z_{t-1} . Sedangkan Model *moving average* dikenal juga sebagai model rata-rata bergerak. Model ini memperlihatkan nilai observasi Z_t bergantung pada nilai kesalahan a_t dan juga nilai kesalahan sebelumnya a_{t-1} . Bentuk umum dari model ARIMA non musiman adalah

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)a_t, \quad (2.6)$$

sedangkan model ARIMA musiman dapat dituliskan berdasarkan model matematis sebagai (Wei, 2006)

$$\Phi_p(B^S)(1-B^S)^D Z_t = \Theta_q(B^S)a_t, \quad (2.7)$$

dengan,

(p, d, q) : orde AR (p), orde *differencing* (d), orde MA (q)
untuk non musiman

- $(P, D, Q)^S$: orde AR (P), orde *differencing* (D), orde MA (Q) untuk data musiman
- $\phi_p(B)$: koefisien komponen AR non musiman dengan derajat p , penjabarannya $(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$
- $\theta_q(B)$: koefisien komponen MA non musiman dengan derajat q , penjabarannya $(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$
- $\Phi_P(B^S)$: koefisien komponen AR musiman S dengan derajat P , dengan $(1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS})$
- $\Theta_Q(B^S)$: koefisien komponen MA musiman S dengan derajat Q , dengan $(1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS})$
- $(1 - B)^d$: operator untuk *differencing* orde d
- $(1 - B^S)^D$: operator untuk *differencing* Musiman S orde D
- S : periode musiman
- a_t : nilai residual pada saat t .

Kombinasi antara (2.8) dan (2.9) menghasilkan model ARIMA musiman multiplikatif yaitu

$$\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D Z_t = \theta_q(B) \Theta_Q(B^S)a_t. \quad (2.8)$$

Model subset ARIMA merupakan bentuk generalisasi model ARIMA yang tidak dapat dinyatakan dalam bentuk umum. Contoh model subset ARIMA(0,0,[1,12,13]) dapat ditulis sebagai

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_{12} a_{t-12} - \theta_{13} a_{t-13} \quad (2.9)$$

dengan θ_1 , θ_{12} dan θ_{13} menyatakan parameter dari model MA. Prosedur pembentukan model ARIMA *Box-Jenkins* umumnya meliputi identifikasi model, estimasi parameter, cek diagnostik, dan peramalan.

2.3.1 Identifikasi Model

Tahap identifikasi merupakan tahap awal pemeriksaan kesta-sioneran data, baik stasioner dalam mean maupun stasioner dalam varians. Setelah diketahui bahwa data telah stasioner dalam

mean dan varians selanjutnya dilakukan penentuan order p , q , P , dan Q berdasarkan plot ACF dan PACF.

A. Stasioneritas dalam *Time series*

Stasioneritas merupakan hal yang penting untuk menentukan model ARIMA. Proses stasioner pada *time series* akan mempunyai keadaan dimana *mean* dan varian adalah konstan. Suatu data dapat dimodelkan dengan ARIMA jika stasioneritas terpenuhi.

a) Stasioner dalam Varians

Suatu deret waktu mempunyai keadaan stasioner dalam varians apabila nilai varians data tidak dipengaruhi oleh deret waktu. Deret waktu yang tidak menunjukkan stasioner dalam varian dapat diatasi dengan menggunakan transformasi Box-Cox, yang umumnya telah dikenalkan oleh Box dan Cox pada tahun 1964. Berikut ini merupakan bentuk-bentuk transformasi Box-Cox yang didasarkan dari nilai-nilai (λ), dtampilkan pada Tabel 2.1 (Wei, 2006)

Tabel 2.1 Transformasi Box-Cox	
Nilai Estimasi λ	Transformasi
-1,0	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1	Z_t (tidak ada transformasi)

transformasi yang umum digunakan adalah transformasi kuadrat. Secara umum, persamaan dari transformasi dapat dituliskan sebagai

$$T(Z_t) = Z_t^{(\lambda)} = \frac{Z_t^\lambda - 1}{\lambda}, \lambda \neq 0 \quad (2.10)$$

dan

$$T(Z_t) = Z_t^{(\lambda)} = \lim_{\lambda \rightarrow 0} \frac{Z_t^\lambda - 1}{\lambda} = \ln(Z_t) \quad \lambda = 0. \quad (2.11)$$

b) Stasioner dalam Mean

Deretan (Z_t) dikatakan stasioner dalam mean jika nilai-nilai data berada berfluktuasi di sekitar garis sejajar dengan sumbu waktu (t) atau disekitar suatu nilai mean yang konstan. Apabila deret waktu tidak stasioner dalam *mean*, dapat diatasi dengan melakukan *differencing*. Proses *differencing* orde ke- d dimana $d \geq 1$ dapat dinyatakan sebagai

$$\nabla^d Z_t = (1 - B)^d Z_t. \quad (2.12)$$

B. Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

ACF merupakan suatu hubungan linear pada data *time series* antara Z_t dengan Z_{t+k} yang dipisahkan oleh waktu pada lag ke- k (Cryer, 1986). Dalam suatu proses stasioner (Z_t), diketahui bahwa nilai $E(Z_t) = \mu$ dan nilai $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$, dengan nilai *mean* dan varian tersebut konstan. Dan kovarian adalah $Cov(Z_t, Z_s)$ yang didasarkan dari fungsi waktu yang berbeda $|t - s|$. Sehingga kovarian antara Z_t dan Z_{t+k} adalah (Wei, 2006)

$$\gamma_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu), \quad (2.13)$$

dan korelasi antara Z_t dan Z_{t+k} dapat dituliskan

$$\rho_k = \frac{cov(Z_t, Z_{t+k})}{\sqrt{var(Z_t)}\sqrt{var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0}, \quad (2.14)$$

dengan $Var(Z_t) = Var(Z_{t+k}) = \gamma_0$, γ_k disebut sebagai fungsi autokovarian dan ρ_k disebut sebagai fungsi autokorelasi (ACF). Sedangkan sampel fungsi autokorelasi yang didasarkan pada observasi Z_1, Z_2, \dots, Z_n dapat dirumuskan

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, \quad k = 0, 1, 2, \dots \quad (2.15)$$

\bar{Z} dihasilkan berdasarkan pada nilai $\bar{Z} = \sum_{t=1}^n \frac{Z_t}{n}$ yang merupakan nilai sampel *mean* dari deret waktu. Plot antara $\hat{\rho}_k$ dengan k disebut sampel *correlogram*.

PACF digunakan untuk mengukur tingkat keeratan hubungan linier antara pasangan data Z_t dan Z_{t+k} setelah pengaruh variabel $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ dianggap terpisah (Cryer, 1986). Autokorelasi parsial antara Z_t dan Z_{t+k} dapat dihitung dengan persamaan

$$\rho_k = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)} \sqrt{\text{Var}(Z_{t+k} - \hat{Z}_{t+k})}}. \quad (2.16)$$

Nilai PACF dinotasikan dalam bentuk ϕ_{kk} , hasil substitusi ρ_i dengan $\hat{\rho}_i$, dengan perhitungan hingga lag ke- k (Wei, 2006). Jika Z_t merupakan deret waktu berdistribusi normal, maka nilai $\phi_{kk} = \text{corr}(Z_t, Z_{t+k} | Z_{t+1}, \dots, Z_{t+k-1})$. Sampel autokorelasi parsial dirumuskan melalui persamaan

$$\phi_{k+1, k+1} = \frac{\rho_{k+1} - \sum_{j=1}^k \phi_{kj} \rho_{k+1-j}}{1 - \sum_{j=1}^k \phi_{kj} \rho_j}, \quad (2.17)$$

dengan $\hat{\phi}_{k+1, j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1, k+1} \hat{\phi}_{k, k+1-j}$, $j = 1, \dots, k$.

Bowerman dan O'Connell (1993) menyatakan bahwa pendugaan model *time series seasonal* maupun yang bukan yaitu model *Autoregressive* (AR), *Moving Average* (MA) atau *Mixed Autoregressive Moving Average* (ARMA) dapat dilihat dari

bentuk ACF dan PACF. Berikut ini merupakan kriteria atau perbedaan dari model AR, MA dan ARMA berdasarkan bentuk ACF dan PACFnya.

Tabel 2.2 Identifikasi Model *Time Series Non Seasonal* Berdasarkan ACF dan PACF

Model	ACF	PACF
MA (q)	terputus setelah lag ke- q	turun secara eksponensial
AR (p)	turun secara eksponensial	terputus setelah lag ke- p
AR (p) or MA (q)	terputus setelah lag ke- q	terputus setelah lag ke- p
ARMA (p, q)	turun secara eksponensial	turun secara eksponensial

Tabel 2.3 Identifikasi Model *Time Series Seasonal* Berdasarkan ACF dan PACF

Model	ACF	PACF
MA (Q)	terputus setelah lag ke- Q	turun secara eksponensial
AR (P)	turun secara eksponensial	terputus setelah lag ke- P
AR (P) or MA (Q)	terputus setelah lag ke- Q	terputus setelah lag ke- P
ARMA (P, Q)	turun secara eksponensial	turun secara eksponensial

2.3.2 Estimasi Dan Pengujian Parameter

Terdapat beberapa metode yang dapat digunakan untuk melakukan estimasi parameter, salah satunya adalah *ordinary least square*. Dan pada bab ini hanya akan dijelaskan estimasi parameter dengan menggunakan *ordinary least square*. Metode *least square* merupakan suatu metode yang dilakukan dengan cara meminimumkan jumlah kuadrat residual. Selanjutnya akan ditunjukkan ilustrasi estimasi parameter untuk model AR(1), model umumnya adalah

$$Z_t - \mu = \phi_1(Z_{t-1} - \mu) + a_t, \quad (2.18)$$

model ini dapat dilihat sebagai suatu model regresi dengan peubah peramalan atau prediktor Z_{t-1} dan peubah respon Z_t . Untuk model AR(1), jika dinyatakan dalam bentuk fungsi dari jumlah kuadrat bersyarat yaitu

$$S_c(\phi, \mu) = \sum_{t=2}^n a_t^2 = \sum_{t=2}^n ((Z_t - \mu) - \phi_1(Z_{t-1} - \mu))^2. \quad (2.19)$$

Berdasar prinsip dari metode *least square*, penaksiran μ dan ϕ dilakukan dengan meminimumkan $S(\phi, \mu)$. Melalui cara dengan menurunkan $S(\phi, \mu)$ terhadap μ dan ϕ . Jika $\partial S_c / \partial \mu = 0$, maka

$$\begin{aligned} \frac{\partial S_c}{\partial \mu} &= \sum_{t=2}^n 2(Z_t - \mu) - \phi_1(Z_{t-1} - \mu)(-1 + \phi) = 0 \\ \Leftrightarrow &\left\{ 2(-1 + \phi) \sum_{t=2}^n [(Z_t - \mu) - \phi_1(Z_{t-1} - \mu)] = 0 \right\} \times \frac{1}{2(-1 + \phi)} \\ \Leftrightarrow &\sum_{t=2}^n [(Z_t - \mu) - \phi_1(Z_{t-1} - \mu)] = 0 \\ \Leftrightarrow &\sum_{t=2}^n [(Z_t - \phi_1 Z_{t-1} - (1 - \phi_1)\mu)] = 0 \\ \Leftrightarrow &\sum_{t=2}^n Z_t - \phi_1 \sum_{t=2}^n Z_{t-1} - \sum_{t=2}^n [(1 - \phi_1)\mu] = 0 \\ \Leftrightarrow &\sum_{t=2}^n Z_t - \phi_1 \sum_{t=2}^n Z_{t-1} - (n-1)(1 - \phi_1)\mu = 0 \\ \Leftrightarrow &(n-1)(1 - \phi_1)\mu = Z_t - \phi_1 \sum_{t=2}^n Z_{t-1} \end{aligned}$$

dengan demikian diperoleh

$$\mu = \frac{\sum_{t=2}^n Z_t - \phi_1 \sum_{t=2}^n Z_{t-1}}{(n-1)(1 - \phi_1)}. \quad (2.20)$$

Untuk n yang besar berlaku

$$\frac{1}{n-1} \sum_{t=2}^n Z_t \approx \frac{1}{n-1} \sum_{t=2}^n Z_{t-1} \approx \bar{Z} \quad (2.21)$$

Tanpa memperhatikan nilai ϕ , persamaan (2.20) dapat disederhanakan menjadi

$$\hat{\mu} \approx \frac{1}{1-\phi} (\bar{Z} - \phi \bar{Z}) \approx \bar{Z}. \quad (2.22)$$

Dengan cara yang sama, operasi turunan terhadap ϕ , yaitu

$$\begin{aligned} \frac{\partial S_c}{\partial \phi} &= \sum_{t=2}^n 2((Z_t - \bar{Z}) - \phi_1(Z_{t-1} - \bar{Z}))(-Z_{t-1} + \bar{Z}) = 0 \\ \Leftrightarrow & -2 \sum_{t=2}^n [(Z_t - \bar{Z}) - \phi_1(Z_{t-1} - \bar{Z})\phi_1(Z_{t-1} - \bar{Z})] = 0 \\ \Leftrightarrow & -2 \sum_{t=2}^n [(Z_t - \bar{Z})(Z_{t-1} - \bar{Z}) - \phi_1(Z_{t-1} - \bar{Z})^2] = 0 \\ \Leftrightarrow & -2 \sum_{t=2}^n [(Z_t - \bar{Z})(Z_{t-1} - \bar{Z}) + 2\phi_1 \sum_{t=2}^n (Z_{t-1} - \bar{Z})^2] = 0 \\ \Leftrightarrow & \left\{ 2 \sum_{t=2}^n [(Z_t - \bar{Z})(Z_{t-1} - \bar{Z})] = 2\phi_1 \sum_{t=2}^n (Z_{t-1} - \bar{Z})^2 \right\} \times \frac{1}{2} \\ \Leftrightarrow & \sum_{t=2}^n [(Z_t - \bar{Z})(Z_{t-1} - \bar{Z}) - \phi_1 \sum_{t=2}^n (Z_{t-1} - \bar{Z})^2] = 0 \end{aligned}$$

Sehingga diperoleh nilai taksiran ϕ sebagai berikut

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_t - \bar{Z})^2}. \quad (2.23)$$

Nilai-nilai persamaan 2.22 dan 2.23 merupakan taksiran parameter μ dan ϕ (Cryer & Chan, 2008). Setelah parameter didapatkan kemudian dilakukan pengujian signifikansi parameter. Dimisalkan β merupakan parameter model ARIMA yang men-

cakup ϕ dan θ . $\hat{\beta}$ adalah taksiran dari β . Hipotesis dari pengujian signifikansi parameter adalah

$$H_0 : \beta = 0$$

$$H_1 : \beta \neq 0$$

$$\text{Statistik uji : } t = \frac{\hat{\beta}}{SE(\hat{\beta})}. \quad (2.24)$$

Daerah penolakan H_0 jika $|t| > t_{\alpha/2, df=n-n_p}$ maka H_0 ditolak dengan n_p adalah banyaknya parameter yang ditaksir, atau tolak H_0 jika $P\text{-value}$ kurang dari α dengan α adalah tingkat signifikansi atau kesalahan jenis 1 (Bowerman dan O'Connell, 1993).

2.3.3 Pemeriksaan Diagnostik

Setelah estimasi parameter, selanjutnya dilakukan dengan meninjau asumsi model telah terpenuhi atau tidak. Asumsi dasar adalah residual $\{a_t\}$ *white noise* dan berdistribusi normal, i.i.d $N(0, \sigma_a^2)$. Pemeriksaan diagnostik merupakan pencapaian melalui analisis yang cermat dari deret residual, karena deret residual adalah produk dari estimasi parameter.

a) Asumsi Residual *White Noise*

Pemeriksaan residual *white noise*, dapat dilakukan dengan menghitung sampel ACF dan PACF. Penggunaan test lain untuk pemeriksaan residual *white noise* dapat dilakukan dengan menggunakan uji Ljung-Box. Adapun hipotesis dalam pengujian ini adalah

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$$

$$H_1 : \text{minimal ada satu } \rho_k \neq 0, \text{ untuk } k = 1, 2, \dots, K$$

$$\text{Statistik uji : } Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2, \quad (2.25)$$

n merupakan banyak pengamatan, $\hat{\rho}_k$ menunjukkan ACF residual pada lag ke k dan K adalah maksimum lag. Daerah penolakan H_0

jika nilai $Q > \chi^2_{\alpha; (K-p-q)}$ maka H_0 ditolak dengan p dan q merupakan orde AR dan MA atau dapat juga dilihat berdasarkan P -value, jika P -value lebih besar α maka residual memenuhi asumsi *white noise* (Cryer, 1986; Wei, 2006).

b) Asumsi Residual Berdistribusi Normal

Pemeriksaan berdistribusi secara normal, dapat dilakukan dengan membuat sebuah histogram dan membandingkannya dengan standar distribusi normal menggunakan *goodness of fit*. Pemeriksaan apakah varian telah konstan, dapat memeriksanya dengan plot dari residual. Pengujian asumsi ini dapat dilakukan dengan menggunakan *Kolmogorov Smirnov Test*. Hipotesis untuk melakukan pengujian ini dapat ditulis

$H_0 : F(a_t) = F_0(a_t)$ (residual berdistribusi normal)

$H_1 : F(a_t) \neq F_0(a_t)$ (residual tidak berdistribusi normal)

$$\text{Statistik Uji} : D = \sup_{a_t} |S(a_t) - F_0(a_t)|, \quad (2.26)$$

dimana $S(a_t)$ adalah fungsi peluang kumulatif yang dihitung dari data sampel, $F_0(a_t)$ merupakan fungsi peluang kumulatif dari distribusi normal, \sup sebagai nilai *supremum* untuk semua x dari $|S(a_t) - F_0(a_t)|$. Daerah kritis yang berlaku jika H_0 ditolak maka $D_{hit} > D_{(1-\alpha), n}$ dengan n adalah ukuran sampel (Daniel, 1989).

2.3.4 Peramalan

Peramalan merupakan suatu tahapan dengan tujuan untuk menghasilkan hasil peramalan yang optimum tanpa *error* atau memiliki *error* yang sekecil-kecilnya. Proses peramalan suatu pengamatan *time series* dilakukan dengan meminimumkan *mean square error* (MSE). Peramalan suatu model ARIMA(p, d, q) pada waktu $t = n + l$, dapat ditulis sebagai

$$\hat{Z}_n(l) = E(Z_{n+l} | Z_t, t \leq n) = \sum_{j=1}^{\infty} \pi_j^{(l)} Z_{n-j+l}. \quad (2.27)$$

Error peramalan untuk $j > 0$ adalah

$$e_n(l) = Z_{n+l} - \hat{Z}_n(l) = \sum_{j=0}^{l-1} \psi_j a_{n+1-j}, \quad (2.28)$$

sedangkan *error* varians dari model adalah

$$\text{Var}(e_n(l)) = \sigma_a^2 \sum_{j=0}^{l-1} \psi_j^2, \quad (2.29)$$

sehingga untuk proses normal maka batas peramalan $(1 - \alpha)100\%$ adalah

$$Z_n(l) \pm Z_{\alpha/2} \left[1 + \sum_{j=0}^{l-1} \psi_j^2 \right]^{1/2} \sigma_a. \quad (2.30)$$

dengan $Z_{\alpha/2}$ adalah deviasi normal standar sedemikian hingga $P(Z > Z_{\alpha/2}) = \alpha/2$ (Wei, 2006).

2.4 Time Series Outlier

Outlier pada data *time series* merupakan gangguan kejadian yang mengakibatkan pengamatan tidak tepat pada suatu data. Dampak dari *outlier* pada data yaitu dapat mendatangkan suatu masalah dalam analisis data, membuat keputusan dan kesimpulan menjadi tidak reliabel dan tidak valid. Sehingga prosedur yang dilakukan adalah mendeteksi dan menghilangkan pengaruh dari *outlier* tersebut (Wei, 2006). Model *outlier* umum dengan k *outlier* yang beragam dapat dituliskan dengan persamaan

$$Z_t = \sum_{j=1}^k \omega_j v_j(B) I_t^{T_j} + X_t, \quad (2.31)$$

$I_t^{(T_j)}$ merupakan variabel *outlier* pada waktu ke- T_j dan dinotasikan sebagai

$$I_t^{T_j} = \begin{cases} 1 & , t = T_j \\ 0 & , t \neq T_j. \end{cases} \quad (2.32)$$

dengan X_t merupakan model *time series* yang bebas dari *outlier*,

$$X_t = \frac{\theta(B)}{\phi(B)} a_t, \quad (2.33)$$

dan

$$v_j(B) = \begin{cases} 1, & \text{untuk AO} \\ \frac{\theta(B)}{\phi(B)}, & \text{untuk IO.} \end{cases}$$

Salah satu jenis *outlier* adalah *additive outlier* dan *innovative outlier*. *Additive outlier* memberikan pengaruhnya pada pengamatan ke- T . Sehingga model *additive outlier* dapat dirumuskan

$$Z_t = \frac{\theta(B)}{\phi(B)} a_t + \omega I_t^{(T)}. \quad (2.34)$$

Sedangkan *innovative outlier* berpengaruh pada pengamatan ke- T , $T+1, \dots$, hingga T kembali pada keadaan $\frac{\theta(B)}{\phi(B)}$. Didapatkan pula model *innovative outlier* sebagai

$$Z_t = X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)}. \quad (2.35)$$

Berikut ini adalah langkah-langkah mendeteksi *outlier* dengan metode iteratif yaitu :

1. Memodelkan data dengan asumsi tidak terdapat *outlier* dalam model. Setelah itu menghitung residual dari estimasi model.

$$\hat{e}_t = \frac{\hat{\phi}B}{\hat{\theta}B} Z_t = \hat{\pi}(B) Z_t, \quad (2.36)$$

dengan $\hat{\phi}(B) = (1 - \hat{\phi}_1 B - \dots - \hat{\phi}_p B^p)$ dan $\hat{\theta}(B) = (1 - \hat{\theta}_1 B - \dots$

$- \hat{\theta}_q B^q)$. Kemudian hitung estimasi awal dari $\hat{\sigma}_a^2 = \frac{1}{n} \sum_{t=1}^n \hat{e}_t^2$.

2. Menghitung $\hat{\lambda}_{1,t}$ dan $\hat{\lambda}_{2,t}$ untuk $t = 1, 2, \dots, n$. Persamaannya dapat ditulis

$$\hat{\lambda}_{1,t} = \frac{\tau \hat{\omega}_{AT}}{\sigma_a} \text{ dan } \hat{\lambda}_{2,t} = \frac{\hat{\omega}_{IT}}{\sigma_a}. \quad (2.37)$$

Definisikan $\hat{\lambda}_T = \max_t \max_i \{ |\hat{\lambda}_{i,t}| \}$, dengan T adalah waktu terjadinya $\hat{\lambda}_T$ maksimum. Jika $\hat{\lambda}_T = |\hat{\lambda}_{1,T}| > C$, dimana C merupakan konstanta yang bernilai positif yang biasanya bernilai antara 3 dan 4, maka terjadi AO pada waktu T dengan estimasi efek oleh $\hat{\omega}_{AT}$. Sehingga modelnya adalah

$$\tilde{Z}_t = Z_t - \hat{\omega}_{AT} I_t^{(T_j)}, \quad (2.38)$$

dan residual didefinisikan

$$\tilde{e}_t = \hat{e}_t - \hat{\omega}_{AT} \hat{\pi}(B) I_t^{(T_j)}. \quad (2.39)$$

Jika $\hat{\lambda}_T = |\hat{\lambda}_{2,T}| > C$, maka terjadi IO pada waktu T dengan efek $\hat{\omega}_{IT}$. Sehingga persamaan model dan residualnya adalah

$$\tilde{Z}_t = Z_t - \frac{\hat{\phi}B}{\hat{\theta}B} \hat{\omega}_{IT} I_t^{(T_j)}, \quad (2.40)$$

$$\tilde{e}_t = \hat{e}_t - \hat{\omega}_{IT} I_t^{(T_j)}. \quad (2.41)$$

Estimasi $\tilde{\sigma}_a^2$ kemudian dihitung berdasarkan residual yang baru.

3. Menghitung kembali $\hat{\lambda}_{1,t}$ dan $\hat{\lambda}_{2,t}$ berdasarkan residual yang baru dan $\hat{\sigma}_a^2$ dan ulangi langkah ke-2 hingga semua *outlier* terdeteksi dengan estimasi awal nilai $\pi(B)$ tidak berubah.
4. Menghitung estimasi parameter *outlier* $\omega_1, \omega_2, \dots, \omega_k$ pada waktu T_1, T_2, \dots, T_k terjadi *outlier*, k merupakan banyaknya *outlier*. Sehingga parameter deret berkala berbentuk

$$Z_t = \sum_{j=1}^k \omega_j v_j(B) I_t^{(T_j)} + \frac{\phi B}{\theta B} a_t, \quad (2.42)$$

dimana $v_j(B)=1$ untuk AO dan $v_j(B)=\frac{\phi B}{\theta B}$ untuk IO pada $t =$

T_j . Serta dihitung $\hat{\sigma}_a^2$ dengan residual baru dengan bentuk

$$\hat{a}_t^{(1)} = \hat{\pi}^{(1)}(B) \left[Z_t - \sum_{j=1}^k \hat{\omega}_j \hat{v}_j(B) I_t^{(T_j)} \right] \quad (2.43)$$

estimasi dan lakukan perhitungan ulang σ_a^2 .

2.5 Model Fungsi Transfer

Fungsi transfer merupakan metode peramalan nilai deret waktu (deret *output*) Z_t yang didasarkan nilai-nilai masa lalu deret itu sendiri serta pada satu atau lebih deret waktu lain (deret *input*) yang berhubungan dengan deret waktu tersebut. Bentuk umum dari model fungsi transfer *single input*, dengan deret *output* Z_t dan deret *input* X_t linier adalah (Wei, 2006)

$$Z_t = v(B)X_{t-b} + \eta_t, \quad (2.44)$$

dengan

$$\eta_t = \frac{\theta(B)}{\phi(B)} a_t, \quad (2.45)$$

dan

$$v(B) = \frac{\varpi_s(B)B^b}{\delta_r(B)}, \quad (2.46)$$

dimana $\varpi_s(B) = \varpi_0 - \varpi_1 B - \dots - \varpi_s B^s$ dan $\delta_r(B) = 1 - \delta_1 B - \dots - \delta_r B^r$. Z_t dan X_t adalah deret yang stasioner, η_t merupakan deret *noise*. koefisien model fungsi transfer sering disebut sebagai bobot respon *impulse*.

Identifikasi model fungsi transfer terdapat beberapa tahapan yaitu :

1. Penentuan model ARIMA dan *prewhitening* deret *input*. Setelah model ARIMA untuk deret *input* telah sesuai maka

selanjutnya dilakukan *prewhitening*. Model deret *input* yang telah di *prewhitening* adalah (Wei, 2006)

$$\alpha_t = \frac{\theta_x(B)}{\phi_x(B)} X_t, \quad (2.47)$$

dengan α_t adalah deret yang *white noise* dan $N(0, \sigma_\alpha^2)$.

2. Dilakukan *prewhitening* deret *output*. Deret *output* dimodelkan dengan menggunakan model deret *input*nya. *Prewhitening* deret *output* ini dilakukan dengan cara yang sama dengan deret *input*, yaitu :

$$\beta_t = \frac{\theta_x(B)}{\phi_x(B)} Z_t. \quad (2.48)$$

3. Penghitungan CCF (*crosscorrelation function*) antara deret *input* (α_t) dan *output* (β_t) yang telah dilakukan *prewhitening*. CCF digunakan untuk mengukur tingkat hubungan antar nilai X pada waktu t dengan nilai Z pada waktu $t + k$ (Makridakis, Wheelwright, dan McGee, 1999). Jika fungsi kovarian silang antara X_t dan Z_t adalah

$$\gamma_{xz}(k) = E[(x_t - \mu_x)(x_{t+k} - \mu_z)] \quad (2.49)$$

maka koefisien CCF dari *input* X_t dan *output* Z_t untuk lag ke- k didefinisikan sebagai berikut

$$\rho_{xz}(k) = \frac{\gamma_{xz}(k)}{\sigma_x \sigma_z}, \quad k = 0, \pm 1, \pm 2, \dots \quad (2.50)$$

dengan σ_x dan σ_z standar deviasi dari X_t dan Z_t . CCF diestimasi oleh CCF sampel yang dihitung berdasarkan persamaan berikut

$$\bar{\rho}_{xz}(k) = \frac{\hat{\gamma}_{xz}(k)}{S_x S_z}, \quad k = 0, \pm 1, \pm 2, \dots \quad (2.51)$$

dengan

$$\gamma_{xz}(k) = \begin{cases} \frac{1}{n} \sum_{t=1}^{n-k} (X_t - \bar{X})(Z_{t+k} - \bar{Z}) & k \geq 0, \\ \frac{1}{n} \sum_{t=1-k}^n (X_t - \bar{X})(Z_{t+k} - \bar{Z}) & k < 0, \end{cases} \quad (2.52)$$

$$S_x = \sqrt{\hat{\gamma}_{xx}(0)}, S_z = \sqrt{\hat{\gamma}_{zz}(0)},$$

serta \bar{X} dan \bar{Z} adalah rata-rata sampel dari X_t dan Z_t (Wei, 2006).

4. Penetapan (b, r, s) yang menghubungkan deret *input* dan deret *output*. Nilai b menyatakan bahwa Z_t tidak dipengaruhi nilai X_t hingga periode $t + b$. Nilai r menunjukkan bahwa Z_t berkaitan dengan nilai-nilai masa lalunya. Nilai s menyatakan bahwa berapa lama deret *output* (Z_t) secara terus menerus dipengaruhi oleh nilai-nilai baru deret *input* X_t .

2.6 Uji Lagrange Multiplier (LM)

Pengujian kehomogenan ragam galat yang juga digunakan untuk mendeteksi adanya proses ARCH/GARCH, keheterogenan varians *error* yang dipengaruhi kuadrat *error* periode sebelumnya atau disebut dengan keheterogenan varians *error* bersyarat. Umumnya pengujian ini banyak dilakukan pada model ekonometrik. Pendeteksian adanya proses heteroskedastisitas menggunakan uji *Lagrange Multiplier* didasarkan pada regresi *ordinary least square*. Adapun hipotesis dalam pengujian ini adalah

$$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_m = 0$$

$$H_1 : \text{minimal ada satu } \alpha_j \neq 0, \text{ untuk } j = 1, 2, \dots, m$$

$$\text{Statistik uji : } Q^* = nR^2, \quad (2.53)$$

R^2 menunjukkan besarnya kontribusi varians *error* yang dapat dijelaskan deret waktu sebelumnya. n merupakan banyaknya

pengamatan. m adalah banyak periode waktu sebelumnya yang mempengaruhi varians sekarang. Q^* merupakan distribusi yang secara asimtotik seperti distribusi *chi-square*. c adalah derajat bebas dibawah hipotesis nol. Jika nilai Q^* lebih besar dari nilai tabel $\chi^2_{(\alpha,c)}$ maka hipotesis nol ditolak yang artinya varian residual tak konstan atau terjadi kasus heteroskedastisitas.

2.7 Neural Network

Neural network atau jaringan saraf tiruan diperkenalkan McCulloch dan Pitts pada tahun 1943. Pada dasarnya *neural network* (NN) merupakan salah satu contoh model nonlinear yang mempunyai bentuk fungsional fleksibel dan mengandung beberapa parameter yang tidak dapat diinterpretasikan seperti pada model parametrik. Menurut Haykin (1999), *neural network* atau yang dikenal sebagai jaringan saraf adalah prosesor yang didistribusikan secara massal dan saling berhubungan yang memiliki kecenderungan untuk menyimpan pengetahuan/informasi dan dapat digunakan. *Neural network* menyerupai otak dalam dua hal yaitu

1. Jaringan memperoleh pengetahuan/informasi melalui suatu proses pembelajaran
2. Kekuatan koneksi *interneuron* dikenal sebagai bobot sinaptik yang digunakan untuk menyimpan pengetahuan/informasi.

Dalam Sarle (1994), jaringan saraf adalah suatu jenis regresi nonlinear yang fleksibel dan terdiri dari sejumlah besar neuron, yaitu elemen sederhana linear atau nonlinear, saling berhubungan secara kompleks dan disusun dalam lapisan-lapisan. Jaringan saraf tiruan (*artificial neural network*) digunakan dalam tiga cara utama :

- Sebagai model sistem saraf biologis dan kecerdasan
- Pengendali yang diimplementasikan dalam perangkat keras untuk aplikasi seperti robot
- Sebagai metode analisis data.

Menurut Ripley (1996) penggunaan jaringan saraf tiruan (*neural network*) ditekankan pada masalah-masalah berskala besar, namun sangat fleksibel tak terbatas yang tersusun dari sejumlah parameter. Terdapat beberapa klasifikasi model *artificial neural networks*, salah satunya adalah *Feedforward Neural Network* (FFNN).

2.7.1 Feedforward Neural Network

Model FFNN adalah salah satu bentuk model NN yang dapat dipandang sebagai suatu kelompok model yang sangat fleksibel yang dapat digunakan untuk berbagai aplikasi (Suhartono, 2008). Arsitektur *feedforward neural network* mempunyai tiga komponen yaitu *input layer*, *hidden layer*, dan *output layer*. *Input layer* mendefinisikan semua nilai atribut *input* untuk model data dengan segala probabilitasnya. *Hidden layer* menerima *input* dari *input layer* dan memberikan hasil pada *output layer*. Dalam arsitektur ini, nilai-nilai respon atau output \hat{y} dihitung dengan

$$\hat{Z}_{(k)} = f^r \left[\sum_{j=1}^q \left(\beta_j^r f_j^h \left(\sum_{i=1}^p \gamma_{ij}^h x_{i(k)} + \gamma_j^h \right) + \beta^r \right) \right], \quad (2.54)$$

dengan,


- $\hat{Z}_{(k)}$ = nilai dugaan dari variabel *output*
- $x_{i(k)}$ = variabel *input* sebanyak p
- k = indeks pasangan data $(x_{i(k)}, y_{(k)})$, $k = 1, 2, \dots, n$
- γ_j^h = bias pada neuron ke- j di *hidden layer*
- f_j^h = fungsi aktivasi di neuron ke- j pada *hidden layer*
- β^r = bias pada neuron di *output layer*
- f^r = fungsi aktivasi di neuron pada *output layer*

p adalah jumlah dari *input layer*, q adalah jumlah dari *hidden layer*. *Superscript r* digunakan sebagai indeks *output layer* dan h

sebagai indeks *hidden layer*. f_j^h dan f^r biasanya fungsi *smooth* seperti pada fungsi logistik sigmoid, yaitu:

$$f(Z) = \frac{1}{1 + e^{-Z}}, \quad (2.55)$$

$Z = \hat{Z}_{(k)} = d_{(k)}^r = f^r(v_{(k)}^r)$, $\{\beta_j^r, j = 0, 1, \dots, q\}$ adalah sebuah bobot dari neuron ke- j di *hidden layer* menuju neuron *output layer* dan $\{\gamma_{ij}^h, i = 0, 1, \dots, p; j = 0, 1, \dots, q\}$ adalah bobot dari *input* ke- i menuju neuron ke- j pada *hidden layer* (Suhartono, 2008).



Gambar 2.1 Arsitektur pada Model Neural Network dengan 1 Hidden Layer, 3 Input Layer, 4 Neuron Di Hidden Layer, dan 1 Output Layer.

Gambar 2.1 adalah suatu contoh dari bentuk FFNN dengan 3 input, satu *hidden layer* yang terdiri dari q unit neuron dengan fungsi aktivasi f , dan *output layer* yang hanya terdiri dari satu unit neuron.

2.7.2 Algoritma Backpropagation

Estimasi parameter bobot (*weight*) model *neural network* dilakukan dengan menerapkan algoritma *backpropagation* pada suatu optimisasi *Nonlinier Least Squares*. Implementasinya

adalah dengan *mengupdate* bobot-bobot dengan dua tahapan yaitu *forward* dan *backward*. Dalam prosesnya, algoritma *backpropagation* diterapkan pada pasangan data *training input-output* $(x_{(k)}, z_{(k)})$. Penjabaran algoritma *backpropagation* terdiri dari 5 tahapan sebagai berikut (Haykin, 1999).

1. Pemberian identitas pembobot dengan asumsi tidak ada informasi yang tersedia sebelumnya.
2. Digunakan pasangan data *training* dalam setiap himpunan yang terbentuk, dan dilakukan urutan perhitungan *forward* dan *backward* pada langkah 3 dan 4.
3. Perhitungan *forward*. Bagian ini dilakukan dengan *mengupdate* bobot-bobot pada setiap lapis pasangan data $(x_{(k)}, z_{(k)})$. Penjumlahan nilai-nilai *input* dan bobot pada *hidden layer* di neuron ke- j di lapis ke- h pada data ke- k dilambangkan dengan $v_{j(k)}^h$, yaitu :

$$v_{j(k)}^h = \sum_{i=1}^p \gamma_{ij}^h x_{i(k)} + \gamma_j^h \quad (2.56)$$

output pada *hidden layer* yang terproses di neuron ke- j pada lapis ke- h adalah

$$d_{j(k)}^h = f_j^h(v_{j(k)}^h). \quad (2.57)$$

Dengan cara yang sama, maka penjumlahan nilai-nilai *input* dan bobot dari *hidden layer* ke *output layer* adalah

$$v_{(k)}^r = \sum_{j=1}^q \beta_j^r d_{j(k)}^h + \beta^r \quad (2.58)$$

output pada *output layer* pada lapis ke- r adalah.

$$\hat{z}_{(k)} = d_{(k)}^r = f^r(v_{(k)}^r) \quad (2.59)$$

4. Perhitungan *backward*. Pada bagian ini bobot diupdate setelah pasangan data *input-output* pada data *training* terproses. Bobot-bobot diupdate melalui metode *gradien descent*,

metode optimasi berdasarkan suatu pendekatan linier dari fungsi *error*

$$\Delta w = -\eta Q'(w), \text{ atau } \Delta w = -\eta \frac{\partial Q'(w)}{dw}, \quad \eta > 0, \quad (2.59)$$

η adalah suatu *learning rate*. Q adalah suatu jumlahan dari

$$\text{kuadrat error data training dengan } Q = \frac{1}{2} \sum_{k=1}^n (y_{(k)} - \hat{z}_{(k)})^2.$$

Untuk mendapatkan bobot dilakukan pada tiap-tiap lapis yang dilambangkan dengan γ_{ji}^h dan β_j^r dengan cara meminimumkan Q .

Update bobot pada β_j^r dengan pemrosesan *backward* dari *output layer* ke *hidden layer* adalah

$$\frac{\partial Q(w)}{\partial \beta_j^r} = \frac{\partial Q(w)}{\partial d_{(k)}^r} \frac{\partial d_{(k)}^r}{\partial v_k^r} \frac{\partial v_k^r}{\partial \beta_j^r}, \quad (2.60)$$

$$\frac{\partial Q(w)}{\partial \beta_j^r} = - \sum_{k=1}^n \delta_{(k)}^r d_{j(k)}^h, \quad (2.61)$$

$$\text{dengan } \delta_{(k)}^r = [z_{(k)} - \hat{z}_{(k)}] f^r \left(\sum_{l=1}^q \beta_l^r d_{l(k)}^h + \beta^r \right). \quad \text{dan } w$$

adalah γ_{ji}^h atau β_j^r . Melalui cara yang sama yaitu dilakukan turunan parsial dari Q terhadap β^r adalah

$$\frac{\partial Q(w)}{\partial \beta_j^r} = \frac{\partial Q(w)}{\partial d_{(k)}^r} \frac{\partial d_{(k)}^r}{\partial v_k^r} \frac{\partial v_k^r}{\partial \beta^r}, \quad (2.62)$$

$$\frac{\partial Q(w)}{\partial \beta^r} = - \sum_{k=1}^n \delta_{(k)}^r. \quad (2.63)$$

Selanjutnya *update* bobot pada γ_{ij}^h dari *hidden layer* ke *input layer* adalah

$$\frac{\partial Q(w)}{\partial \gamma_{ij}^h} = \frac{\partial Q(w)}{\partial d_{(k)}^r} \frac{\partial d_{(k)}^r}{\partial v_k^r} \frac{\partial v_k^r}{\partial d_{j(k)}^h} \frac{\partial d_{j(k)}^h}{\partial v_{j(k)}^h} \frac{\partial v_{j(k)}^h}{\partial \gamma_{ji}^h}, \quad (2.64)$$

$$\frac{\partial Q(w)}{\partial \gamma_{ij}^h} = - \sum_{k=1}^n \delta_{j(k)}^h x_{i(k)}, \quad (2.65)$$

dengan $\delta_{j(k)}^h = \delta_{(k)}^r \beta_j^r (f_j^h(v_{j(k)}^h))$ melalui cara yang sama yaitu dilakukan turunan parsial dari Q terhadap γ_j^h adalah (Suhartono, 2007)

$$\frac{\partial Q(w)}{\partial \gamma_{ij}^h} = \frac{\partial Q(w)}{\partial d_{(k)}^r} \frac{\partial d_{(k)}^r}{\partial v_k^r} \frac{\partial v_k^r}{\partial d_{j(k)}^h} \frac{\partial d_{j(k)}^h}{\partial v_{j(k)}^h} \frac{\partial v_{j(k)}^h}{\partial \gamma_j^h}, \quad (2.66)$$

$$\frac{\partial Q(w)}{\partial \gamma_j^h} = - \sum_{k=1}^n \delta_{j(k)}^h. \quad (2.67)$$

Berdasarkan proses *forward* dan *backward*, diperoleh persamaan-persamaan *update* untuk bobot dan bias. Adapun *updating* bobot-bobot dan bias pada *output layer*

$$\beta_j^{r(m+1)} = \beta_j^{r(m)} + \eta \sum_{k=1}^n \delta_{(k)}^{r(m)} d_{j(k)}^{h(m)}, \quad (2.68)$$

$$\beta^{r(m+1)} = \beta^{r(m)} + \eta \sum_{k=1}^n \delta_{(k)}^{r(m)}. \quad (2.69)$$

Sedangkan *updating* bobot-bobot dan bias pada *hidden layer* adalah.

$$\gamma_{ij}^{h(m+1)} = \gamma_{ij}^{h(m)} + \eta \sum_{k=1}^n \delta_{j(k)}^{r(m)} x_{i(k)}, \quad (2.70)$$

$$\gamma_j^{h(m+1)} = \gamma_j^{h(m)} + \eta \sum_{k=1}^n \delta_{j(k)}^h{}^{(m)}. \quad (2.71)$$

5. Iterasi. Iterasi perhitungan *forward* dan *backward* pada poin 3 dan 4 hingga kriteria ditemukan.

2.8 Kriteria Pemilihan Model

Kriteria seleksi model biasanya didasarkan pada kesalahan ramalan yang dihitung dari ramalan *out-sample*. Langkah ini dilakukan dengan menggunakan bagian pertama (*insample*) dari deret waktu untuk membangun model dan sisanya (*outsample*) sebagai evaluasi ramalan. Kriteria pemilihan model untuk *outsample* dapat digunakan dengan kriteria *Root mean square error* (RMSE) dan SMAPE (*Symmetric Mean Absolute Percentage Error*). Sebelumnya terdapat kriteria dengan istilah MAPE, namun terdapat kelemahan dalam MAPE yaitu tidak simetrik. RMSE dirumuskan sebagai (De Gooijer dan Hyndman, 2006)

$$RMSE = \sqrt{\frac{1}{n} \sum_{l=1}^M (Z_{n+l} - \hat{Z}_n(l))^2}, \quad (2.72)$$

sedangkan rumus SMAPE dapat dinyatakan pada persamaan berikut

$$SMAPE = \left(\frac{1}{n} \sum_{l=1}^M \frac{2|Z_{n+l} - \hat{Z}_n(l)|}{(Z_{n+l} + \hat{Z}_n(l))} \right) \times 100 \quad (2.73)$$

dengan Z_{n+l} adalah data aktual *out sample* ke- l , $l = 1, 2, \dots, M$ dan $\hat{Z}_n(l)$ merupakan data hasil ramalan *out sample* ke- l .

2.9 Pasar Modal

Dalam Bursa Efek Indonesia, pasar modal (*capital market*) merupakan pasar untuk berbagai instrumen keuangan jangka panjang yang bisa diperjualbelikan seperti saham, obligasi,

waran, *right*, reksa dana, dan berbagai instrumen derivatif seperti *option*, *futures*, maupun instrumen lainnya. Pasar modal merupakan sarana pendanaan bagi perusahaan maupun institusi lain misalnya pemerintah, dan sebagai sarana bagi kegiatan berinvestasi. Pasar Modal memiliki peran penting bagi perekonomian suatu negara karena pasar modal menjalankan dua fungsi, yaitu pertama sebagai sarana bagi pendanaan usaha atau sebagai sarana bagi perusahaan untuk mendapatkan dana dari masyarakat pemodal (investor). Dana yang diperoleh dari pasar modal dapat digunakan untuk pengembangan usaha, ekspansi, penambahan modal kerja dan lain-lain. Kedua pasar modal menjadi sarana bagi masyarakat untuk berinvestasi pada instrumen keuangan.

Menurut Undang-Undang No. 8 tahun 1995 tentang pasar modal mendefinisikan pasar modal sebagai kegiatan yang bersangkutan dengan penawaran umum dan perdagangan efek, perusahaan publik yang berkaitan dengan efek yang diterbitkannya, serta lembaga dan profesi yang berkaitan dengan efek. Pengertian pasar modal berdasarkan keputusan presiden No. 52 tahun 1976 tentang pasar modal menyebutkan bahwa pasar modal adalah Bursa Efek seperti yang dimaksud dalam undang-undang No. 15 tahun 1952. menurut undang-undang tersebut, bursa adalah gedung atau ruangan yang ditetapkan sebagai kantor dan tempat kegiatan perdagangan efek, sedangkan surat berharga yang dikategorikan efek adalah saham, obligasi serta surat bukti lainnya yang lazim dikenal sebagai efek. Pasar modal di Indonesia dikenal sebagai Bursa Efek Indonesia atau Indonesia *Stock Exchange* (IDX).

2.10 Saham

Saham atau sekuritas merupakan secarik kertas yang menunjukkan hak pemodal yaitu pihak yang memiliki kertas untuk memperoleh bagian dari prospek atau kekayaan organisasi yang menerbitkan sekuritas tersebut, dan berbagai kondisi yang memungkinkan pemodal tersebut menjalankan haknya (Husnan, 2001). Saham dapat didefinisikan sebagai tanda penyertaan modal

seseorang atau pihak (badan usaha) dalam suatu perusahaan atau perseroan terbatas. Berdasarkan Undang-Undang No. 40 tahun 2007 pasal 7 ayat 2 tentang Undang-Undang Perseroan Terbatas (UUPT) dapat kita simpulkan bahwa saham adalah penyertaan modal oleh subjek hukum ke dalam suatu perseroan terbatas pada saat pendirian perseroan terbatas tersebut. Terdapat 2 jenis macam saham yaitu saham biasa dan saham preferen.

1. Saham biasa adalah surat berharga sebagai bukti penyertaan atau pemilikan individu maupun institusi atas suatu perusahaan. Saham sebagai sekuritas yang bersifat ekuitas, memberikan implikasi bahwa kepemilikan saham mencerminkan kepemilikan atas suatu perusahaan.
2. Saham preferen adalah penanaman modal atau kepemilikan pada suatu perusahaan pada tingkat terbatas. Para pemegang saham preferen tidak memiliki hak suara dalam rapat umum pemegang saham (RUPS), tetapi akan dijanjikan sejumlah dividen yang jumlahnya pasti dan tetap dalam persentase tertentu yang pembayarannya lebih didahulukan dibandingkan dividen saham biasa.

Pada Bursa Efek Indonesia, saham yang sebagai instrumen investasi memiliki keuntungan antara lain:

1. Dividen merupakan pembagian keuntungan yang diberikan perusahaan dan berasal dari keuntungan yang dihasilkan perusahaan. Dividen diberikan setelah mendapat persetujuan dari pemegang saham dalam RUPS.
2. *Capital Gain* adalah selisih antara harga jual yang lebih tinggi dari harga jual.

Risiko yang dimungkinkan terjadi ketika melakukan investasi pada instrumen saham adalah

1. *Capital Loss* merupakan kebalikan dari *Capital Gain*, berupa selisih antara nilai jual yang lebih rendah daripada nilai beli saham.
2. Risiko Likuidasi adalah perusahaan yang sahamnya dimiliki, dinyatakan bangkrut oleh Pengadilan, atau perusahaan tersebut

dibubarkan. Dalam hal ini hak klaim dari pemegang saham mendapat prioritas terakhir setelah seluruh kewajiban perusahaan dapat dilunasi.

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Sumber data pada penelitian tugas akhir ini menggunakan data sekunder yang diperoleh dari Bursa Efek Indonesia. Data yang digunakan merupakan besarnya nilai transaksi (jumlah rupiah) penjualan saham harian pada seluruh pasar BEI (Bursa Efek Indonesia) selama periode tahun 2012 hingga 2014.

3.2 Variabel Penelitian

Variabel yang akan digunakan pada penelitian ini terdiri dari respon, prediktor dan variabel *dummy* untuk efek *outlier*, yaitu :

Z_t : Besarnya nilai transaksi jual beli saham harian di Bursa Efek Indonesia.

X_t : IHSG.

I_t : Variabel *dummy outlier*, dengan 1 ketika $t=T$ dan 0 untuk t yang lainnya.

3.3 Langkah Analisis

Langkah-langkah analisis ini bertujuan untuk mendiskripsikan atau menggambarkan serangkain kegiatan analisis yang akan dilakukan dalam penelitian. Langkah-langkah analisis di bawah ini berdasarkan tujuan yang telah dijelaskan pada Bab I. Adapun langkah-langkah analisisnya antara lain :

1. Untuk menjawab tujuan pertama, dilakukan analisis deskriptif pada data besarnya nilai jual beli di BEI. Deskriptif dari besarnya nilai jual beli di BEI meliputi nilai *mean*, *varians*, deviasi standar, median, *kurtosis* dan *skewness*.
2. Dilakukan pemodelan menggunakan ARIMAX dan *neural network* untuk menjawab tujuan kedua. Langkah-langkah analisisnya adalah :


- I. Pertama dilakukan pemodelan ARIMAX, langkah analisisnya sebagai berikut.
 - a. Identifikasi stasioneritas data transaksi saham.
 - b. Ditentukan Model ARIMA sementara.
 - c. Dilakukan estimasi parameter model yang telah didapatkan.
 - d. Dilakukan pengujian signifikansi parameter-parameter model ARIMA.
 - e. Pengujian asumsi *white noise* terhadap residual model.
 - f. Pengujian asumsi berdistribusi normal pada residual model. Jika asumsi kenormalan tidak terpenuhi dapat dilakukan pendeteksian *outlier*.
 - g. Jika tidak terdapat *outlier* maka model yang digunakan adalah ARIMA, namun jika *outlier* signifikan maka dilakukan kembali langkah I.d. hingga I.f.
 - h. Pemodelan ARIMAX.
- II. Kedua dilakukan pemodelan ARIMAX (ARIMA dengan penambahan prediktor) atau Fungsi Transfer, langkah analisisnya sebagai berikut.
 - a. Mempersiapkan deret *input* dan *output*.
 - b. Penentuan model ARIMA dan *prewhitening* deret *input*.
 - c. *Prewhitening* deret *output*.
 - d. Penghitungan CCF (*crosscorrelation function*).
 - e. Penetapan (b, r, s) yang menghubungkan deret *input* dan deret *output*.
 - f. Penaksiran awal deret *noise* dan penetapan model ARIMA dari deret *noise*.
 - h. Pengujian Diagnostik Model Fungsi Transfer (pengujian residual berdistribusi normal).
 - i. Pemodelan fungsi transfer.
- III. Ketiga dilakukan pengujian heteroskedastisitas pada residual model ARIMAX dan fungsi transfer menggunakan uji *Lagrange Multiplier (LM)*. Jika tidak terjadi kasus heteroskedastisitas, maka model yang


digunakan adalah ARIMAX dan fungsi transfer. Jika terjadi kasus heteroskedastisitas maka model yang digunakan adalah ARIMAX-GARCH.


- IV. Keempat dilakukan pemodelan menggunakan model *neural network*, langkah-langkahnya adalah :
 - a. Penentuan jumlah neuron pada *input layer* seperti pada *input* model ARIMAX.
 - b. Penentuan jumlah neuron pada *hidden layer* untuk pemodelan.
 - c. Memilih RMSE terkecil dari model 1 *neuron* hingga 10 *neuron*.
 - d. Pemodelan *neural network*.
3. Langkah analisis untuk menjawab tujuan yang ketiga adalah dilakukan pemodelan perbandingan model ARIMAX dan *neural network*.
 - a. Dilakukan perbandingan model berdasarkan kriteria pemilihan model *outsample* dengan menggunakan RMSE dan SMAPE. Nilai RMSE dan SMAPE terkecil merupakan model yang paling baik.
 - b. Prediksi besarnya nilai transaksi saham harian dengan model yang terbaik.

3.4 Diagram Alir Analisis

Diagram alir langkah analisis yang digunakan dalam penelitian ini dipaparkan sebagai berikut.







Gambar 3.1 Diagram Alir Analisis

BAB IV ANALISIS DAN PEMBAHASAN

Pada bab ini dijelaskan hasil analisis dan pembahasan mengenai hasil ramalan nilai transaksi jual beli saham harian di Bursa Efek Indonesia. Data yang digunakan merupakan jumlah rupiah yang diperoleh dari transaksi penjualan saham pada tahun 2012 hingga 2014. Pendekatan metode yang digunakan untuk meramalkan nilai transaksi penjualan saham di Bursa Efek Indonesia antara lain ARIMAX, fungsi transfer dan *Neural Network*.

4.1 Karakteristik Nilai Transaksi Penjualan Saham Harian Di Bursa Efek Indonesia


Analisis deskriptif dilakukan untuk menjelaskan mengenai gambaran umum dari data jumlah rupiah jual beli saham dan IHSG mulai bulan Januari 2012 hingga Desember 2014. Hasil analisis deskriptif yang telah dilakukan ditunjukkan dalam Tabel 4.1.

Tabel 4.1 Karakteristik Nilai Transaksi Saham Harian Per Tahun (dalam Triliyun)

Tahun	Mean	Variance	Stdev	Min	Max	Skew-ness	Kurtosis
2012	4,537	1,367	1,169	1,01	8,791	0,72	1,33
2013	6,238	5,064	2,250	2,64	20,97	2,51	10,82
2014	6,006	4,096	2,024	3,11	18,35	2,46	9,58
2012-2014	5,589	4,063	2,016	1,01	20,97	2,41	10,98

Rata-rata nilai transaksi saham di Bursa Efek Indonesia pada tahun 2013 mengalami peningkatan sebesar 6,238 triliyun dari rata-rata tahun 2012 sebesar 4,537. Sedangkan pada tahun 2014, nilai transaksi penjualan saham sebesar 6,006 triliyun. Nilai deviasi standar dari nilai transaksi saham memiliki variasi yang tinggi, yaitu sebesar 2,016 triliyun. Di tahun 2012 menuju tahun 2013 dan 2014 terdapat selisih nilai transaksi penjualan saham

yang tinggi, hal tersebut dikarenakan oleh perubahan kebijakan perdagangan saham oleh BEI. Tahun 2013, BEI memajukan jam perdagangan 30 menit lebih awal dan menerapkan sesi *pre-closing* dan *post-trading* untuk meningkatkan volume perdagangan. Di awal tahun 2014 terdapat perubahan parameter perdagangan mengenai *lot size* (kesempatan transaksi lebih banyak) atau *tick price* (peluang *matching* semakin besar). Dugaan ini didukung oleh Gambar 4.1 yang menunjukkan bahwa terdapat kenaikan yang signifikan rata-rata nilai transaksi jual beli saham pada di tahun 2012 hingga tahun 2013, 2014.



Gambar 4.1 Rata-rata Nilai Transaksi jual beli Saham pada Tahun 2012-2014


Berdasarkan deskriptif nilai transaksi jual beli saham yang ditunjukkan oleh Tabel 4.1, berikut adalah informasi yang dapat diperoleh :

- Tahun 2012, Nilai transaksi jual beli saham terendah (minimum) yaitu sebesar 1,01 triliun pada hari Senin tanggal 27 Agustus 2012, dikarenakan sistem perdagangan saham BEI mengalami gangguan (*error*). Transaksi jual beli saham tertinggi (maksimum) yaitu sebesar 8,79 triliun pada hari Jumat tanggal 30 November 2012, disebabkan oleh adanya penggorengan saham atau *stock cornering* dan *crossing* saham. Penggorengan saham adalah suatu cara untuk merekayasa harga saham oleh beberapa oknum bandar/pe-modal dengan tujuan menaikkan harga saham untuk

memperoleh keuntungan yang sebesar-besarnya. Dan *crossing* saham merupakan perdagangan saham yang dilakukan oleh anggota bursa yang sama, saham yang sama, jumlah yang sama dan harga yang sama. *Crossing* biasa dilakukan oleh pemodal yang besar dengan transaksi jumlah lot yang besar pula, sehingga akibatnya dapat meningkatkan transaksi jual beli saham.

- Tahun 2013, nilai transaksi jual beli saham terendah yaitu sebesar 2,64 triliyun pada hari Selasa tanggal 24 Desember 2013. Transaksi perdagangan saham menurun dikarenakan adanya kebijakan *tapering off* atau mengurangi nilai pembelian aset oleh Bank sentral AS yang menyebabkan para investor asing banyak melepas sahamnya. Nilai transaksi saham paling tinggi atau maksimum adalah pada hari Senin tanggal 25 Maret 2013 sebesar 20,97 triliyun, hal tersebut dikarenakan adanya pengumuman peraturan jam perdagangan baru dan pengurangan jumlah lot dari 500 lembar menjadi 100 lembar. Akibatnya adalah transaksi jual beli saham meningkat karena modal yang dibutuhkan oleh investor untuk membeli saham semakin kecil.
- Kemudian di tahun 2014, nilai transaksi jual beli saham terendah atau minimum adalah sebesar 3,11 triliyun yaitu pada hari Senin tanggal 6 Januari 2014. Hal tersebut disebabkan oleh perubahan peraturan fraksi saham dari 5 kelompok menjadi 3 kelompok fraksi saham. Perubahan peraturan ini menyebabkan *trader* jangka pendek cenderung menahan diri untuk bertransaksi karena belum terbiasa dengan perubahan fraksi saham, akibatnya transaksi perdagangan saham menurun. Hal ini juga dapat menjelaskan bahwa telah banyak investor-investor kecil yang mulai berpartisipasi pada perdagangan saham di pasar modal. mendapatkan keuntungan yang kecil karena terbatasnya pergerakan saham pula. Nilai transaksi jual beli saham yang terbesar yaitu sebesar 18, 35 triliyun pada hari Rabu tanggal 3 September 2014. Hal ini karena terdapat isu mengenai membaiknya perekonomian


Indonesia serta relatif stabilnya nilai inflasi yang diikuti dengan meningkatnya IHSG menjadikan pendorong penguatan bursa domestik, sehingga banyak investor yang melakukan transaksi jual beli saham. Dan berdasar pada nilai *skewness* dan *kurtosis* yang telah diperoleh, dapat dijelaskan bahwa persebaran data nilai transaksi saham harian tidak berdistribusi normal. Karena nilai *Z-skewness* dan *Z-kurtosis* yang lebih besar dari nilai normal standar 1,96. Disajikan pula *box-plot* nilai transaksi jual beli saham pada Gambar 4.2 dan Gambar 4.3 berikut ini. Gambar 4.2 dan 4.3 ditampilkan untuk mengetahui rata-rata nilai transaksi jual beli saham di setiap hari dan minggu apakah berbeda atau sama.



Gambar 4.2 *Box-plot* Nilai Transaksi jual beli Saham Hari Senin-Jumat

Gambar 4.2 menunjukkan nilai transaksi jual beli saham harian di Bursa Efek Indonesia pada hari Senin hingga Jumat relatif sama, baik pada rata-rata maupun penyebarannya. Diketahui juga, terdapat banyak kejadian yang ekstrim (*outlier*) pada transaksi perdagangan saham. Kejadian-kejadian yang ekstrim ini, secara tidak langsung telah dijelaskan melalui penjelasan sebelumnya. *Outlier* tertinggi terjadi pada hari Senin yaitu bertepatan tanggal 25 Maret 2013, pada hari ini terjadi perubahan peraturan jam perdagangan baru dan pengurangan jumlah lot yang memberikan dampak positif kepada investor karena modal yang dibutuhkan untuk membeli saham semakin


kecil, akibatnya transaksi jual beli saham meningkat. Informasi mengenai kejadian ektrim yang lain adalah pada hari Rabu tanggal 18 September 2013 pada hari tersebut Bank sentral AS mengumumkan kebijakan *tapering* yaitu tetap melakukan pembelian aset, pengumuman tersebut membuat IHSG meningkat sehingga membuat investor-investor asing maupun lokal melakukan transaksi pembelian saham. Tanggal 3 September 2014 juga mempunyai nilai transaksi tertinggi, dikarenakan adanya isu membaiknya perekonomian Indonesia, diikuti dengan inflasi yang stabil dan meningkatnya IHSG. Gambar 4.3 memberikan informasi yang sama dengan Gambar 4.2. rata-rata maupun penyebaran data nilai transaksi jual beli saham harian di Bursa Efek Indonesia pada hari minggu ke-1 hingga minggu ke-5 adalah relatif sama. Kejadian-kejadian ektrim yang paling tinggi diketahui pada minggu ke-1, yang bertepatan pada tanggal 3 September 2014. Kemudian pada minggu ke-3 yaitu pada tanggal 18 September 2013, dan minggu ke-5 yaitu tanggal 25 Maret 2013.



Gambar 4.3 Box-plot Nilai Transaksi jual beli Saham Minggu 1 Hingga 5

Selanjutnya ditampilkan *box-plot* rata-rata nilai transaksi jual beli saham di setiap bulan (Januari-Desember) pada Gambar 4.4. Gambar 4.4 menjelaskan bahwa persebaran dari data nilai transaksi jual beli saham lebih bervariasi. Rata-rata terbesar ditemukan pada bulan Maret dan Mei. Rata-rata pada bulan Maret

membesar karena diduga adanya perubahan peraturan jam perdagangan serta perubahan jumlah lot dan fraksi saham. Pada bulan Maret memiliki nilai transaksi jual beli saham paling tinggi sebesar 20,97 triliyun. Sedangkan pada bulan Mei, diduga karena membaiknya perekonomian AS di awal bulan Mei 2013 setelah mengalami krisis. Hal ini menyebabkan bursa-bursa global dan negara-negara Eropa membaik. Selain itu, hal ini berkaitan dengan kebijakan baru oleh BI yang membatasi nilai nominal nota debit dan transfer kredit dalam penyelenggaraan sistem *kliring*.



Gambar 4.4 Box-plot Nilai Transaksi jual beli Saham Bulan Januari-Desember

Tabel 4.2 Deskriptif Nilai Transaksi Saham Harian Per Bulan (dalam Triliyun)

Bulan	Mean	StDev	Var	Min	Max
Januari	4,652	1,165	1,357	1,102	8,1
Februari	5,549	1,135	1,289	2,77	7,451
Maret	6,41	2,916	8,503	2,544	20,973
April	6,032	1,565	2,449	3,128	12,614
Mei	6,546	2,537	6,436	2,709	15,848
Juni	5,78	2,398	5,751	2,198	13,49
Juli	5,447	2,197	4,828	2,904	15,717
Agustus	5,22	1,66	2,757	1,006	9,98
September	5,715	2,712	7,353	3,012	18,349
Oktober	5,207	1,387	1,924	3,755	12,019
November	4,925	1,026	1,053	3,298	8,81
Desember	5,607	1,476	2,180	2,638	9,412

Penjelasan Gambar 4.4 didukung oleh Tabel 4.2 yang menunjukkan bahwa rata-rata nilai transaksi jual beli saham paling tinggi adalah di bulan Maret dan Mei. Kemudian berdasarkan *outlier-outlier* atau kejadian-kejadian ekstrim yang terdapat pada nilai transaksi jual beli saham di Bursa Efek Indonesia, menjelaskan bahwa kejadian mengenai perubahan jam perdagangan saham serta perubahan jumlah lot dan kelompok fraksi saham memberikan kaitan yang paling besar pada nilai transaksi jual beli saham di BEI. Berikutnya ditampilkan Tabel 4.3 untuk melihat rata-rata nilai transaksi jual beli saham per hari di setiap tahun dan per minggu di setiap tahunnya.

Tabel 4.3 Rata-rata Nilai Transaksi Saham Harian Per Hari di Setiap Tahun dan Per Minggu di Setiap Tahun

		Tahun		
		2012	2013	2014
Hari/Tahun	Jumat	4,926	6,222	6,213
	Kamis	4,641	6,598	5,956
	Rabu	4,644	6,531	6,415
	Selasa	4,344	6,264	5,867
	Senin	4,151	5,628	5,597
Minggu/Tahun	1	4,595	5,811	5,921
	2	4,621	6,445	6,035
	3	4,449	6,108	6,232
	4	4,400	6,122	5,777
	5	4,663	6,827	6,145


Berdasarkan deskriptif nilai transaksi jual beli saham yang ditunjukkan oleh Tabel 4.1, berikut adalah informasi yang dapat diperoleh :

- Tahun 2012, rata-rata nilai transaksi jual beli saham terbesar (maksimum) yaitu sebesar 4,926 triliun pada hari Senin. Kemudian pada minggu yang mempunyai rata-rata nilai transaksi terbesar adalah di minggu kelima dengan rata-rata nilai transaksi sebesar 4,663 triliun.
- Di tahun 2013, rata-rata nilai transaksi jual beli saham terbesar terjadi pada hari Kamis dengan rata-rata nilai transaksi saham

sebesar 6,598 triliyun. Sedangkan pada minggu yang mempunyai rata-rata nilai transaksi terbesar (maksimum) adalah di minggu kelima dengan nilai rata-rata transaksi jual beli saham sebesar 6,827 triliyun.

- Tahun 2014, rata-rata nilai transaksi jual beli saham terbesar (maksimum) yaitu sebesar 6,415 triliyun yang bertepatan pada hari Rabu. Kemudian pada minggu yang mempunyai rata-rata nilai transaksi terbesar adalah di minggu ketiga 6,232 triliyun.


Secara umum dapat dijelaskan bahwa rata-rata nilai transaksi jual beli saham di setiap tahun akan selalu berubah. Hal tersebut dikarenakan nilai transaksi saham selalu bergerak fluktuatif dan tidak terpatok oleh hari atau minggu. Penjelasan diatas secara visual ditunjukkan oleh Gambar 4.5.



Gambar 4.5 Bar Chart Nilai Transaksi jual beli Saham Per Hari di Setiap Tahun dan Per Minggu di Setiap Tahun

Time series plot pada Gambar 4.6 menunjukkan bahwa data nilai transaksi jual beli saham tidak terlihat memiliki *trend* atau kenaikan yang terlalu mencolok. Selain itu, secara visual dapat dilihat bahwa terdapat banyak nilai-nilai transaksi yang tinggi atau besar. Nilai-nilai transaksi yang ekstrim mempunyai nilai transaksi di atas 15 triliyun, sedangkan rata-rata nilai transaksi jual beli saham pada periode tahun 2012 hingga tahun 2013 hanya sebesar 5,6 triliyun. Selisih perbedaan nilai transaksi tersebut, diduga akibat dari suatu kejadian yang dapat memberikan efek pada nilai transaksi jual beli saham. Ringkasan kejadian-kejadian

yang memberikan nilai transaksi paling besar ditampilkan pada Tabel 4.4.



Gambar 4.6 Time Series Plot Nilai Transaksi jual beli Saham

Tabel 4.4 Peristiwa yang Memberikan Nilai Transaksi Terbesar

No	Waktu ke-t	Tanggal	Keterangan
1	228	30 November 2012	Terjadi penggorengan saham (<i>stock cornering</i>) dan <i>crossing saham</i>
2	303	25 Maret 2013	Pengumuman perubahan jam perdagangan dan jumlah lot serta fraksi saham
3	330	2 Mei 2013	Adanya isu perekonomian AS yang membaik
4	335	10 Mei 2013	Bursa saham wall street menguat dan indeks DJIA dan S&P 500 akibat perekonomian AS yang membaik awal Mei 2013
5	350	31 Mei 2013	Kebijakan baru oleh BI yang membatasi nilai nominal nota debit dan transfer kredit dalam penyelenggaraan sistem <i>kliring</i>
6	422	18 September 2013	Bank sentral AS mengumumkan kebijakan <i>no tapering</i> yaitu tetap melakukan pembelian aset
7	488	24 Desember 2013	Efek dari kebijakan <i>Tapering</i> yang diumumkan oleh Bank sentral AS pada tanggal 23 Desember 2014

Tabel 4.5 Peristiwa yang Memberikan Nilai Transaksi Terbesar (Lanjutan)


No	Waktu ke-t	Tanggal	Keterangan
8	493	6 Januari 2014	Pengumuman peraturan perubahan jumlah lot dan fraksi saham
9	616	10 Juli 2014	Pemilihan presiden 2014
10	650	3 September 2014	IHSG meningkat, indeks harga dari semua kelompok meningkat

4.2 Pemodelan Nilai Transaksi Penjualan Saham Harian dengan Menggunakan Model ARIMAX (ARIMA dengan Tambahan Efek *Outlier*)

Model ARIMAX merupakan generalisasi dari model ARIMA. ARIMA merupakan model yang sederhana dan telah banyak digunakan pada *time series* analysis. Dalam metodologi *time series*, ARIMA Box-Jenkins mempunyai beberapa langkah prosedur untuk membentuk model. Langkah-langkah pembentukan model penelitian ini didasarkan pada prosedur Box-Jenkins tersebut.


4.2.1 Identifikasi Model pada Data Nilai Transaksi Penjualan Saham di Bursa Efek Indonesia

Identifikasi model merupakan tahapan awal untuk melakukan peramalan (*forecasting*). Identifikasinya meliputi pengujian kestasioneran data dan penentuan order dari AR dan MA. Untuk pengujian kestasioneran data terhadap varian dapat digunakan transformasi Box-Cox. Sedangkan pengujian kestasioneran data terhadap *mean* dapat dilihat berdasarkan *time series plot* dan plot ACF dari data. Gambar 4.6 merupakan *Box Plot* data transaksi penjualan saham. Hasil menunjukkan bahwa data belum stasioner dalam varian, ditandai dengan nilai *rounded value*-nya sebesar -0,27, juga nilai LCL dan UCL yang kisarannya belum melewati nilai 1,00 yaitu antara -0,45 sampai -0,08. Untuk mendapatkan data yang stasioner terhadap varian, dilakukan transformasi data menjadi $(Z_t)^{-0,27}$.



Gambar 4.7 Box-Cox Plot Data Nilai Transaksi Penjualan Saham


Untuk menguji stasioneritas data dalam *mean* dapat dilihat dari plot *time series* dan plot ACF. Data nilai transaksi jual beli saham belum stasioner dalam *mean*, hal ini ditunjukkan oleh plot ACF (*Autocorrelation Function*) yang digambarkan pada 4.6.b membentuk pola *dies down* atau turun secara lambat dan *time series plot* pada 4.6.a memperlihatkan banyak data yang ekstrim. Dikarenakan terdapat banyak lag yang keluar (*dies down*) dari batas ACF dan data nilai transaksi jual beli saham belum berfluktuasi disekitar garis *mean*, diindikasikan bahwa data belum stasioner terhadap *mean*. Sehingga data yang telah ditranformasi diperlukan pula proses *differencing*.



Gambar 4.8 a. Plot ACF, dan b. Plot PACF

Plot ACF dan PACF setelah dilakukan tranformasi dan *differencing* 1 ditunjukkan pada gambar 4.9. Gambar 4.9.a memperlihatkan data setelah dilakukan tranformasi dan

differencing 1 telah berfluktuasi disekitar *mean*. Sehingga diindikasikan bahwa data telah stasioner terhadap *mean* dan varian. Pada plot ACF 4.9.b menunjukkan pola *cuts off after lag 3* atau terputus setelah lag 3 dan PACF pada gambar 4.9.c menunjukkan pola *dies down*. Sehingga dugaan model yang dapat digunakan adalah ARIMA (0,1,3) dan ARIMA (4,1,[5]).



Gambar 4.9 a. Time series Plot, b. Plot ACF, dan c. Plot PACF (Data Setelah Dilakukan Transformasi dan *Differencing*).

4.2.2 Estimasi Parameter Dan Uji Signifikansi Model

Estimasi parameter merupakan langkah kedua dari prosedur ARIMA Box-Jenkins untuk melihat parameter-parameter yang diduga signifikan. Estimasi parameter dilakukan pada model-model dugaan yang didapatkan yaitu ARIMA (0,1,3) dan ARIMA (4,1,[5]). Kemudian berdasarkan model yang diduga

dilakukan pengujian signifikansi secara parsial. Apabila parameter-parameter model telah signifikan, maka model dapat digunakan dan dapat dilanjutkan pada tahap selanjutnya. Akan tetapi jika model tidak memiliki parameter-parameter yang signifikan, maka model tersebut tidak digunakan.

Tabel 4.6 Hipotesis Masing-Masing Model ARIMA

Hipotesis		Taraf Signifikan
ARIMA (0,1,3)	ARIMA (4,1,[5])	
$H_0 : \theta_1 = 0$	$H_0 : \phi_1 = 0$	0,05
$H_1 : \theta_1 \neq 0$	$H_1 : \phi_1 \neq 0$	
$H_0 : \theta_2 = 0$	$H_0 : \phi_2 = 0$	
$H_1 : \theta_2 \neq 0$	$H_1 : \phi_2 \neq 0$	
$H_0 : \theta_3 = 0$	$H_0 : \phi_3 = 0$	
$H_1 : \theta_3 \neq 0$	$H_1 : \phi_3 \neq 0$	
	$H_0 : \phi_4 = 0$	
	$H_1 : \phi_4 \neq 0$	
	$H_0 : \theta_5 = 0$	
	$H_1 : \theta_5 \neq 0$	

Tabel 4.7 Uji Signifikansi Parameter Model ARIMA

Model	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
(0,1,3)	$\theta_1 = 0,50040$	0,03744	13,36	<0,0001
	$\theta_2 = 0,13540$	0,04160	3,25	0,0012
	$\theta_3 = 0,08874$	0,03744	2,37	0,0181
(4,1,[5])	$\phi_1 = -0,51546$	0,03732	-13,81	<0,0001
	$\phi_2 = -0,40522$	0,04154	-9,75	<0,0001
	$\phi_3 = -0,39659$	0,04302	-9,22	<0,0001
	$\phi_4 = -0,27037$	0,04526	-5,97	<0,0001
	$\theta_5 = 0,14550$	0,04752	3,06	0,0023

Tabel 4.7 menunjukkan bahwa kedua model dugaan ARIMA (0,1,3) dan ARIMA (4,1,[5]) yang didapatkan mempunyai parameter-parameter yang signifikan. Hal tersebut dapat dilihat berdasarkan *P-value* dari model, dimana *P-value* kurang dari taraf signifikan (α) sebesar 0,05 sehingga keputusan yang diambil adalah tolak H_0 . Kedua model dugaan dapat digunakan dan dilakukan pemeriksaan diagnostik.

4.2.3 Pemeriksaan Diagnostik

Langkah prosedur selanjutnya adalah melakukan pemeriksaan diagnostik pada kedua model yang telah signifikan. Pemeriksaan diagnostik terdiri dari pemeriksaan asumsi *white noise* dan berdistribusi normal. Uji residual *white noise* ditunjukkan berdasarkan Tabel 4.8 dengan hipotesis

Hipotesis:

$H_0: \rho_1 = \rho_2 = \dots = \rho_K = 0$ (residual *white noise*).

H_1 : minimal ada satu $\rho_j \neq 0$ (residual tidak *white noise*).

Tabel 4.8 Pengujian Asumsi *White Noise* Model ARIMA

Model	Hingga Lag	Chi-square	P-value
(0,1,3)	6	7,07	0,0696
	12	8,65	0,4698
	18	10,53	0,7850
	24	14,98	0,8238
	30	23,51	0,6571
	36	25,40	0,8252
	42	28,79	0,8846
	48	29,57	0,9631
(4,1,[5])	6	1,15	0,2837
	12	2,59	0,9199
	18	4,44	0,9855
	24	9,50	0,9641
	30	17,42	0,8658
	36	18,81	0,9580
	42	21,80	0,9779
	48	22,84	0,9951

Selanjutnya dilakukan pengujian asumsi residual berdistribusi normal menggunakan uji *Kolmogorov-Smirnov*. Berdasarkan uji KS pada Tabel 4.9 disimpulkan bahwa residual belum berdistribusi normal. Hal ini diduga karena pengaruh banyaknya outlier pada residual ARIMA nilai transaksi penjualan saham.

Tabel 4.9 Pengujian Asumsi Distribusi Normal Model ARIMA

Model	<i>D</i>	<i>P-value</i>
(0,1,3)	0,065699	<0,0001
(4,1,[5])	0,065988	<0,0001

4.2.4 Deteksi *Outlier*

Outlier merupakan nilai ekstrim pada *time series* yang dapat memberikan efek pada waktu ke-*t* dan seterusnya. Identifikasi adanya *outlier* ini salah satunya dapat dilihat ketika asumsi normalitas tidak terpenuhi. Sehingga perlu dilakukan pemeriksaan dan pengujian ulang dengan mengikutsertakan *outlier* dalam model. *Outlier* pada model diperlihatkan melalui Tabel 4.6. Berdasar tabel tersebut, diperoleh dua puluh kejadian yang ekstrim (*outlier* pada kedua model dugaan ARIMA (0,1,3) dan ARIMA (4,1,[5])). Jenis *outlier* yang muncul adalah *additive*, yang artinya kejadian-kejadian ekstrim (*outlier*) memberikan efek pada hari itu juga atau pada saat ke-*t* dengan $t=T$. Sebagai contoh, ditemukan *outlier* pada $t=1$ (hari Senin tanggal 2 Januari 2012), pada saat itu terjadi pembukaan peraturan perdagangan hari pertama Bursa Efek Indonesia, banyak investor yang menahan melakukan transaksi penjualan saham yang mengakibatkan transaksi penjualan saham menurun. Kemudian pada $t=162$ (hari Senin tanggal 27 Agustus 2012), terjadi kerusakan sistem koneksi *remote trading* di Bursa Efek Indonesia, akibatnya sistem perdagangan saham terganggu menjadi tidak lancar dan dilakukan penutupan transaksi lebih awal, sehingga nilai transaksi jual beli saham menurun drastis karena tidak banyak investor yang melakukan transaksi pada hari itu.

Tabel 4.10 Identifikasi *Outlier* Pada Model ARIMA

Model	<i>Outlier</i>	jenis	<i>Chi-Square</i>	P-value
(0,1,3)	162	<i>Additive Outlier</i>	74,49	<0,0001
	1	<i>Additive Outlier</i>	57,52	<0,0001
	650	<i>Additive Outlier</i>	31,23	<0,0001
	489	<i>Additive Outlier</i>	25,79	<0,0001
	598	<i>Additive Outlier</i>	17,09	<0,0001
	303	<i>Additive Outlier</i>	17,17	<0,0001
	391	<i>Additive Outlier</i>	15,25	<0,0001
	274	<i>Additive Outlier</i>	15,22	<0,0001
	330	<i>Additive Outlier</i>	14,85	0,0001
	104	<i>Additive Outlier</i>	14,92	0,0001
	610	<i>Additive Outlier</i>	14,97	0,0001
	110	<i>Additive Outlier</i>	14,73	0,0001
	172	<i>Additive Outlier</i>	15,01	0,0001
	422	<i>Additive Outlier</i>	14,96	0,0001
	468	<i>Additive Outlier</i>	14,78	0,0001
	690	<i>Additive Outlier</i>	14,63	0,0001
	145	<i>Additive Outlier</i>	11,98	0,0005
	178	<i>Additive Outlier</i>	11,89	0,0006
	423	<i>Additive Outlier</i>	11,91	0,0006
	616	<i>Additive Outlier</i>	11,28	0,0008
(4,1,[5])	162	<i>Additive Outlier</i>	74,22	<0,0001
	1	<i>Additive Outlier</i>	57,66	<0,0001
	650	<i>Additive Outlier</i>	32,68	<0,0001
	489	<i>Additive Outlier</i>	25,39	<0,0001
	598	<i>Additive Outlier</i>	19,29	<0,0001
	303	<i>Additive Outlier</i>	18,28	<0,0001
	110	<i>Additive Outlier</i>	16,86	<0,0001
	391	<i>Additive Outlier</i>	15,85	<0,0001
	274	<i>Additive Outlier</i>	15,85	<0,0001
	690	<i>Additive Outlier</i>	13,81	0,0002
	468	<i>Additive Outlier</i>	13,65	0,0002
	104	<i>Additive Outlier</i>	13,46	0,0002
	330	<i>Additive Outlier</i>	13,52	0,0002
	422	<i>Additive Outlier</i>	13,44	0,0002

Tabel 4.11 Identifikasi *Outlier* Pada Model ARIMA (Lanjutan)

(4,1,[5])	610	<i>Additive Outlier</i>	12,81	0,0003
	172	<i>Additive Outlier</i>	12,66	0,0004
	178	<i>Additive Outlier</i>	12,22	0,0005
	616	<i>Additive Outlier</i>	11,85	0,0006
	423	<i>Additive Outlier</i>	11,58	0,0007
	145	<i>Additive Outlier</i>	11,27	0,0008

Tabel 4.10 dan 4.11 menunjukkan beberapa *outlier* yang terdapat pada kedua model dengan *P-value* yang kurang dari taraf signifikan (α) sebesar 0,05. Sehingga dapat dikatakan bahwa *outlier-outlier* yang teridentifikasi di masing-masing model dapat memberikan efek signifikan pada data yang digunakan. Berdasarkan hasil analisis, ditemukan *outlier-outlier* dengan jenis *additive outlier* pada kedua model dengan ringkasan pada Tabel 4.12.

Tabel 4.12 Ringkasan *Outlier* Pada Model ARIMA

<i>Outlier</i> pada t ke-	Bulan	Kejadian
1	2 Januari 2012	Peresmian pembukaan perdagangan hari pertama Bursa Efek Indonesia (BEI) tahun 2012
162	27 Agustus 2012	Terjadi kerusakan sistem koneksi sistem <i>remote trading</i> di BEI
303	25 Maret 2013	Pengumuman peraturan jam perdagangan baru dan pengurangan jumlah <i>lot</i>
422	18 September 2013	Bank sentral AS mengumumkan kebijakan <i>No Tapering</i> atau pemangkasan stimulus.
423	19 September 2013	Efek dari kebijakan <i>No Tapering</i> yang diumumkan oleh Bank sentral AS tanggal 18 September
489	27 Desember 2013	Efek dari kebijakan <i>Tapering</i> yang diumumkan oleh Bank sentral AS
616	10 Juli 2014	Pemilihan presiden 2014

Tabel 4.13 Uji Signifikansi Parameter Model ARIMA dengan Penambahan *Outlier*


Model	Estimasi	SE	t-value	P-value
(0,1,3)	$\theta_1 = 0,50714$	0,03782	13,41	<0,0001
	$\theta_2 = 0,14935$	0,04247	3,52	0,0005
	$\theta_3 = 0,18806$	0,03789	4,96	<0,0001
	$\omega_{162} = 0,28737$	0,03207	8,96	<0,0001
	$\omega_1 = 0,29250$	0,02293	12,76	<0,0001
	$\omega_{650} = -0,18605$	0,03213	-5,79	<0,0001
	$\omega_{489} = -0,16494$	0,03216	-5,13	<0,0001
	$\omega_{598} = -0,13562$	0,03204	-4,23	<0,0001
	$\omega_{303} = -0,13326$	0,03201	-4,16	<0,0001
	$\omega_{391} = -0,12113$	0,03209	-3,78	0,0002
	$\omega_{274} = 0,12267$	0,03204	3,83	0,0001
	$\omega_{330} = -0,11411$	0,03221	-3,54	0,0004
	$\omega_{104} = -0,11357$	0,03207	-3,54	0,0004
	$\omega_{610} = -0,12217$	0,03203	-3,81	0,0001
	$\omega_{110} = 0,12329$	0,03208	3,84	0,0001
	$\omega_{172} = -0,11980$	0,03202	-3,74	0,0002
	$\omega_{422} = -0,11026$	0,03205	-3,44	0,0006
	$\omega_{468} = -0,10995$	0,03216	-3,42	0,0007
	$\omega_{690} = -0,11108$	0,03202	-3,47	0,0006
(4,1,[5])	$\phi_1 = -0,54646$	0,03796	-14,39	<0,0001
	$\phi_2 = -0,44700$	0,04241	-10,54	<0,0001
	$\phi_3 = -0,50720$	0,04265	-11,89	<0,0001
	$\phi_4 = -0,34171$	0,04680	-7,30	<0,0001
	$\theta_5 = 0,25481$	0,05011	5,09	<0,0001
	$\omega_{162} = 0,27821$	0,03356	8,29	<0,0001
	$\omega_1 = 0,28131$	0,02669	10,54	<0,0001
	$\omega_{650} = -0,18402$	0,03361	-5,47	<0,0001
	$\omega_{489} = -0,15980$	0,03376	-4,73	<0,0001
	$\omega_{598} = -0,13965$	0,03351	-4,17	<0,0001
	$\omega_{303} = -0,13387$	0,03351	-3,99	<0,0001
	$\omega_{110} = 0,13125$	0,03358	3,91	<0,0001
	$\omega_{391} = -0,12465$	0,03363	-3,71	0,0002
	$\omega_{274} = 0,12662$	0,03353	3,78	0,0002
	$\omega_{690} = -0,11473$	0,03350	-3,42	0,0007

Tabel 4.13 menjelaskan hasil estimasi dan uji signifikansi parameter dengan memasukkan pengaruh *outlier* pada model. Hasil estimasi dan pengujian signifikansi parameter ditampilkan seperti berikut. Hasil estimasi dan uji signifikansi pada Tabel 4.13 menunjukkan parameter-parameter pada kedua model adalah signifikan. Tahap selanjutnya adalah dilakukan kembali pemeriksaan diagnostik residual *white noise* dan berdistribusi normal. Pemeriksaan asumsi *white noise* ditunjukkan pada Tabel 4.14.

Tabel 4.14 Pengujian Asumsi *White Noise* Model ARIMA dengan Penambahan *Outlier*

Model	Hingga Lag	Chi-square	P-value
(0,1,3)	6	4,31	0,2302
	12	11,98	0,2146
	18	18,42	0,2411
	24	23,08	0,3398
	30	30,06	0,3114
	36	32,93	0,4706
	42	33,52	0,7174
	48	35,93	0,8307
(4,1,[5])	6	2,54	0,1112
	12	17,24	0,0159
	18	20,90	0,0749
	24	24,09	0,1929
	30	29,36	0,2493
	36	31,89	0,4221
	42	34,00	0,6105
	48	36,96	0,7295

Tabel 4.14 menunjukkan pada model ARIMAX (0,1,3) telah *white noise*, karena semua P-value yang diperoleh lebih besar dari taraf signifikan 0,05. Sedangkan untuk model ARIMAX (4,1,[5]) belum terlihat *white noise*. Karena pada lag 12 P-value yang didapatkan masih lebih kecil dari taraf signifikan 0,05. Sehingga diperlukan identifikasi pada residual model ARIMAX (4,1,[5]) melalui plot ACF.



Gambar 4.10 Plot Residual ARIMAX (4,1,[5])

Gambar 4.10 memperlihatkan bahwa lag 11 keluar dari batasan nilai residual model. Oleh demikian untuk langkah selanjutnya lag 11 dimasukkan dalam model.

Tabel 4.15 Uji Signifikansi Parameter Model ARIMAX (4,1,[5,11])

Model	Estimasi	SE	t-value	P-value
(4,1,[5,11])	$\phi_1 = -0,56834$	0,03748	-15,16	<0,0001
	$\phi_2 = -0,48196$	0,04155	-11,60	<0,0001
	$\phi_3 = -0,55092$	0,04257	-12,94	<0,0001
	$\phi_4 = -0,38914$	0,04784	-8,13	<0,0001
	$\theta_5 = 0,31503$	0,05043	6,25	<0,0001
	$\theta_{11} = 0,12567$	0,03726	3,37	0,0008
	$\omega_{162} = 0,28611$	0,03345	8,55	<0,0001
	$\omega_1 = 0,28599$	0,02460	11,63	<0,0001
	$\omega_{650} = -0,18754$	0,03349	-5,60	<0,0001
	$\omega_{489} = -0,16480$	0,03365	-4,90	<0,0001
	$\omega_{598} = -0,13249$	0,03337	-3,97	<0,0001
	$\omega_{303} = -0,13298$	0,03337	-3,98	<0,0001
	$\omega_{110} = 0,14405$	0,03346	4,30	<0,0001
	$\omega_{391} = -0,12398$	0,03346	-3,71	0,0002
	$\omega_{274} = 0,12785$	0,03342	3,83	0,0001
	$\omega_{690} = -0,10295$	0,03339	-3,08	0,0021

Tabel 4.15 menunjukkan parameter-parameter pada model ARIMAX (4,1,[5,11]) telah signifikan. Hal tersebut dikarenakan

P-value yang diperoleh kurang dari α sebesar 0,05. Oleh karena itu, model ARIMAX (4,1,[5,11]) dilanjutkan pada tahap pemeriksaan diagnostik. Pemeriksaan diagnostik residual *white noise* tertera pada Tabel 4.16.

Tabel 4.16 Pengujian Asumsi *White Noise* Model ARIMAX (4,1,[5,11])

Model	Hingga Lag	Chi-square	P-value
(4,1,[5,11])	12	12,38	0,0540
	18	15,48	0,2161
	24	17,67	0,4773
	30	23,02	0,5193
	36	26,17	0,6664
	42	27,51	0,8444
	48	29,48	0,9275

Hasil pemeriksaan menunjukkan bahwa residual model telah *white noise* pada lag 12 hingga lag ke 48. Hal tersebut dapat ditunjukkan pada P-value yang melebihi taraf signifikan sebesar 0,05. Pemeriksaan diagnostik selanjutnya adalah melakukan pengujian berdistribusi normal pada residual model ARIMAX (0,1,3) dan ARIMAX (4,1,[5,11]). Hasil pengujian residual kedua model ditampilkan pada Tabel 4.17.

Tabel 4.17 Pengujian Asumsi Distribusi Normal Model ARIMAX.

Model	D	P-value
(0,1,3)	0,032722	0,0643
(4,1,[5,11])	0,03304	0,0587

Tabel di atas menunjukkan P-value dari kedua model telah melebihi taraf signifikan α sebesar 0,05, nilai P yang diperoleh adalah sebesar 0,0643 dan 0,0587, artinya residual dari kedua model ARIMAX telah berdistribusi normal. Setelah dilakukan prosedur atau tahapan pengujian residual maka didapatkan model ARIMAX yang memenuhi asumsi yaitu ARIMAX (0,1,3) dan ARIMAX (4,1,[5]). Berikut merupakan persamaan matematis dari kedua model ARIMAX tertera pada Tabel 4.18.


Tabel 4.18 Persamaan Model ARIMAX.

Model	Persamaan
(0,1,3)	$Z_t^* = Z_{t-1} + a_t - 0,50714u_{t-1} - 0,14935u_{t-2}$ $- 0,18806u_{t-3} + 0,28737I_{162} + 0,29250Q_1$ $- 0,18605I_{650} - 0,16494I_{489} - 0,13562I_{598}$ $- 0,13329I_{303} - 0,12111I_{391} - 0,12267I_{274}$ $- 0,11411I_{330} - 0,11357I_{104} - 0,2217I_{610}$ $- 0,12329I_{110} - 0,11980I_{172} - 0,11026I_{422}$ $- 0,10995I_{468} - 0,11108I_{690}$
(4,1,[5,11])	$Z_t^* = Z_{t-1} + 0,568Z_{t-1} - 0,086Z_{t-2} - 1,033Z_{t-3}$ $+ 0,94Z_{t-4} - 0,389Z_{t-5} + a_t - 0,315a_{t-5}$ $- 0,1257a_{t-11} + 0,28914I_{162} + 0,2891I_1$ $- 0,18754I_{650} - 0,16480I_{489} - 0,13249I_{598}$ $- 0,13298I_{303} - 0,14405I_{110} - 0,12398I_{391}$ $- 0,12785I_{274} - 0,10295I_{690}$

Model di atas merupakan model dengan bentuk transformasi $\lambda = -0,27$ sehingga model $Z_t = (Z_t^*)^{-1/0,27}$. Sebagai contoh, penjelasan model ARIMAX (0,1,3) yaitu nilai transaksi jual beli saham hari ini berkaitan pada nilai transaksi saham satu hari sebelumnya dan kesalahan pada satu hari, dua hari, tiga hari sebelumnya. Ditambah dengan *outlier* atau kejadian ekstrim sebagai contoh mengenai pengumuman pembukaan perdagangan saham ($t=1$), terjadi kerusakan sistem koneksi *remote trading* perdagangan saham ($t=162$), perekonomian Indonesia meningkat serta relatif sta-bilnya dengan diikuti inflasi yang stabil serta IHSG meningkat ($t=650$), adanya kebijakan *tapering* yang diumumkan oleh Bank sentral AS ($t=489$), terjadi pengumuman peraturan perubahan jam perdagangan baru dan jumlah lot serta fraksi saham ($t=303$), akibat efek krisis perekonomian di Eropa, Bursa Asia dan regional melemah ($t=110$), adanya kebijakan *no tapering* yaitu tetap melakukan pembelian asset oleh Bank Sentral

$AS(t=422)$. sebesar 0,289 pada nilai transaksi jual beli saham dengan syarat variabel lain konstan.

Perbandingan visual antara data aktual, *fits*, data *outsample* serta nilai ramalan dari kedua model ditampilkan dalam bentuk plot pada Gambar 4.11.



Gambar 4.11 a. Time Series Plot antara *Fits*, *Aktual*, *Outsample*, dan *Forecast* ARIMAX (4,1,[5,11]), b. ARIMAX (0,1,3).

Hasil ramalan *outsample* pada model ARIMAX masih menunjukkan selisih yang sangat besar dari nilai aktualnya. Sehingga selanjutnya dilakukan analisis dengan metode ARIMAX (ARIMA dengan penambahan prediktor IHSG) atau model fungsi transfer. Pada model ini, diperoleh nilai kebaikan model untuk *insample* dan *outsample* pada Tabel 4.19.


Tabel 4.19 Nilai Kriteria Pemilihan Model ARIMAX.

Model	<i>Insample</i>	<i>Outsample</i>	
	RMSE _{in}	RMSE _{out}	SMAPE
ARIMAX (0,1,3)	1,3195	1,7928	18,66%
ARIMAX (4,1,[5,11])	1,4383	1,8660	20,05%

Hasil diperoleh bahwa nilai kriteria pemilihan model berdasarkan *insample* dan *outsample*, memiliki selisih yang tidak terlalu jauh. Nilai RMSE dan SMAPE yang paling kecil adalah model ARIMAX (4,1,[5,11]).


4.3 Pemodelan Nilai Transaksi Penjualan Saham Harian dengan Menggunakan Model Fungsi Transfer (ARIMA dengan Tambahan Variabel Prediktor)

Dalam pemodelan fungsi transfer, akan diprediksi nilai transaksi saham harian berdasarkan pengaruh dari IHSG. Tahap awal pemodelan fungsi transfer adalah melakukan proses *prewhitening* deret *input* IHSG dan deret *output* nilai transaksi saham. Proses *prewhitening* merupakan suatu tahapan untuk mendapatkan model ARIMA, baik pada deret *input* maupun deret *output*, dengan residual yang telah *white noise*. Tahapan ini harus dilakukan karena salah satu syarat dalam membentuk model fungsi transfer adalah residual dari deret *input* dan *output* harus memenuhi asumsi *white noise*.




Gambar 4.12 Time Series Plot IHSG

Gambar 4.12 mengindikasikan bahwa data IHSG telah stasioner dalam varian tetapi belum stasioner dalam *mean*. Untuk membuktikan indikasi awal bahwa data IHSG telah stasioner terhadap varian, dapat dilihat hasil uji Box-Cox pada Gambar 4.13. Hasil uji Box-Cox menunjukkan nilai LCL dan UCL telah melewati nilai 1, yang artinya data IHSG telah stasioner dalam varian. Selain itu berdasar *rounded value* yang diperoleh sebesar 1, dapat dikatakan bahwa data IHSG telah stasioner terhadap varian karena jika varian sama dengan 1, maka varian dari data tersebut cenderung sama atau homogen.




Gambar 4.13 Box-Cox Plot IHSG

Dugaan bahwa data IHSG belum stasioner dalam *mean* dapat dilihat berdasarkan plot ACF yang ditampilkan pada Gambar 4.14. Berdasarkan gambar terlihat plot ACF berpola turun sangat lambat. Sehingga diperlukan proses *differencing* untuk menstasionerkan *mean* IHSG. Untuk plot PACF terlihat membentuk pola *cut off* atau terpotong pada lag 1 dengan nilai korelasi parsial hampir mendekati satu. Oleh karena itu proses *differencing* akan dilakukan dengan menggunakan *differencing* 1. Hasil proses *differencing* data nilai transaksi jual beli saham digambarkan kembali pada plot ACF dan PACF yang tertera pada Gambar 4.15.



Gambar 4.14 a. ACF, b. PACF IHSG



Gambar 4.15 a. ACF, b. PACF IHSG (Setelah *Differencing*)

Gambar 4.15 menunjukkan plot ACF dan PACF dari data IHSG setelah *differencing* 1. Pada plot ACF maupun PACF terlihat membentuk pola *dies down* turun cepat. Beberapa lag yang keluar dari batas ACF adalah 1, 3, 12, dan 33. Sehingga model dugaan ARIMA yang sesuai untuk IHSG adalah ARIMA $([1,12],1,[3,33])$. Orde ini digunakan untuk melakukan estimasi parameter model dugaan, uji signifikansi parameter dan uji asumsi residual model dugaan dengan hasil tertera pada Tabel 4.20.

Tabel 4.20 Uji Signifikansi Parameter Model IHSG

Model	Estimasi	SE	t-value	P-value
([1,12],1,[3,33])	$\phi_1 = 0,07790$	0,03749	2,08	0,0380
	$\phi_{12} = 0,09333$	0,03746	2,49	0,0129
	$\theta_3 = 0,13172$	0,03695	3,57	0,0004
	$\theta_{33} = 0,13765$	0,03754	3,67	0,0003


Estimasi pengujian signifikansi model IHSG pada tabel 4.20, didapatkan hasil bahwa seluruh parameter telah signifikan karena P-value kurang dari $\alpha(0,05)$. Selanjutnya dilakukan pemeriksaan diagnostik dengan memeriksa apakah residual memenuhi asumsi *white noise*. Pengujian asumsi *white noise*

menggunakan statistik uji Ljung-Box. Hasil pengujian asumsi ditampilkan pada Tabel 4.21.

Tabel 4.21 Pengujian Asumsi *White Noise* Model IHSG

Model	Hingga Lag	Chi-square	P-value
([1,12],1,[3,33])	6	4,63	0,0988
	12	10,88	0,2085
	18	18,86	0,1702
	24	29,95	0,0706
	30	37,22	0,0714
	36	43,68	0,0817
	42	50,63	0,0825
	48	56,99	0,0906

Berdasar hasil pengujian diperoleh kesimpulan bahwa residual telah *white noise* dikarenakan P-value lebih besar α (0,05). Sehingga dapat dikatakan model dugaan deret *input* IHSG telah memenuhi asumsi pada tahap *prewhitening*. Selanjutnya dibentuk *crosscorrelation function* antara deret *input* dengan deret *output* yang telah melalui proses *prewhitening*, untuk mendapatkan nilai b , r , s yang akan digunakan dalam estimasi parameter model fungsi transfer. Selain itu, *cross-correlation function* (CCF) juga akan menunjukkan seberapa besar pengaruh deret *input* terhadap deret *output*.



Gambar 4.16 Plot CCF antara Nilai Transaksi Penjualan Saham dengan IHSG


Gambar 4.16 menunjukkan plot CCF antara nilai transaksi saham harian dengan IHSG. IHSG berpengaruh signifikan

terhadap nilai transaksi penjualan saham pada lag ke-0 atau IHSG memberikan efek pada saat ke- t (hari ini). Berdasarkan plot CCF tersebut dapat diduga nilai $b=0$ dan karena tidak terdapat lag lain yang signifikan, maka $s=0$, sedangkan $r=0$ karena plot tidak menunjukkan pola tertentu. Berdasarkan uji signifikansi diketahui nilai estimasi parameter b diperoleh sebesar 0,0035274 dan *P-value* sebesar 0,0302. artinya parameter b telah signifikan. Residual model fungsi transfer sementara dengan b, r, s (0,0,0) belum memenuhi asumsi *white noise*, hal ini dapat dilihat di tabel 4.22.

Tabel 4.22 Pengujian Asumsi *White Noise* Nilai Transaksi Penjualan Saham dengan b, r, s (0,0,0)

Hingga Lag	DF	<i>Chi-square</i>	<i>P-value</i>
6	6	110,05	<0,0001
12	12	114,09	<0,0001
18	18	115,62	<0,0001
24	24	125,24	<0,0001
30	30	137,89	<0,0001
36	36	142,61	<0,0001
42	42	148,90	<0,0001
48	48	150,75	<0,0001

Residual *white noise* apabila statistik uji *chi-square* lebih kecil dari nilai $\chi^2_{0,05,df}$ atau *P-value* lebih kecil dari $\alpha(0,05)$, sehingga asumsi *white noise* belum terpenuhi. Maka perlu ditambahkan deret *noise* dalam estimasi parameter, indikasi adanya deret *noise* ini dapat ditentukan berdasarkan plot ACF dan PACF dari residual model sementara fungsi transfer. Jika terdapat lag yang terjadi *peak* atau keluar batas, maka dapat diduga sebagai lag yang dapat digunakan sebagai deret pengganggu. Hasil indikasi adanya deret *noise* ditampilkan pada Gambar 4.17.



Gambar 4.17 a. ACF, b. PACF Residual Nilai Transaksi Penjualan Saham dengan b, r, s (0,0,0)

Gambar 4.17 tampak terjadi *peak* pada lag 1 pada plot ACF. Model yang diduga sebagai deret *noise* adalah ARMA (1,1). Langkah selanjutnya dilakukan estimasi dan uji signifikansi parameter model fungsi transfer b, r, s (0,0,0) dengan deret *noise* ARMA (1,1) yang ditampilkan pada Tabel 4.23. Langkah ini dilakukan untuk melihat parameter-parameter model fungsi transfer dengan deret *noise* ARMA (1,1) telah signifikan atau sebaliknya.

Tabel 4.23 Uji Signifikansi Parameter Model Fungsi Transfer ARIMA ([1,12],1,[3,33]) dengan b, r, s (0,0,0) dan Deret *Noise* ARMA (1,1)

Parameter	Estimasi	SE	t-value	P-value
ϕ_1	0,29178	0,04090	7,13	<0,0001
θ_1	0,93088	0,01550	60,05	<0,0001
ϖ_0	0,0029976	0,0007315	4,10	<0,0001

Berdasar hasil estimasi pengujian signifikansi didapatkan hasil bahwa seluruh parameter model fungsi transfer telah signifikan. Hal tersebut dapat dijelaskan melalui P-value yang lebih kecil dari taraf signifikan α sebesar 0,05. Dikarenakan pengujian parameter telah signifikan, untuk selanjutnya dapat dilakukan pemeriksaan diagnostik dengan memeriksa apakah

residual memenuhi asumsi *white noise*. Hasil pengujian asumsi *white noise* ada pada Tabel 4.24.

Tabel 4.24 Uji *White Noise* Model Fungsi Transfer ARIMA ([1,12],1,[3,33]) dengan b, r, s (0,0,0) dan deret *noise* ARMA (1,1)

Hingga Lag	DF	<i>Chi-square</i>	<i>P-value</i>
6	4	8,14	0,0865
12	10	10,88	0,3668
18	16	13,05	0,6693
24	22	21,58	0,4853
30	28	31,64	0,2895
36	34	34,76	0,4316
42	40	41,44	0,4076
48	46	43,19	0,5908

Hasil analisis memperlihatkan *P-value* lebih besar dari taraf signifikan α sebesar 0,05, sehingga asumsi *white noise* terpenuhi. Selanjutnya dilakukan pengujian normalitas dari residual. Untuk uji residual distribusi normal dapat menggunakan uji Kolmogorov-Smirnov. Berdasarkan uji KS didapatkan nilai Statistik KS 0,13235 dengan *P-value* <0,01, yang artinya residual belum memenuhi asumsi berdistribusi normal. Ketidaknormalan ini diduga diakibatkan karena adanya *outlier* atau kejadian ekstrim pada data nilai transaksi penjualan saham. Oleh karena itu, Selanjutnya perlu dilakukan identifikasi dan pengujian terhadap adanya *outlier* pada model fungsi transfer. Hasil estimasi dan pengujian signifikansi dari model fungsi transfer ARIMA ([1,12],1,[3,33]), b, r, s (0,0,0) dan deret *noise* ARMA (1,1) dengan penambahan *outlier* ditampilkan pada Tabel 4.25 dan 4.26.

Tabel 4.25 Uji Signifikansi Parameter Model Fungsi Transfer ARIMA ([1,12],1,[3,33]), b, r, s (0,0,0) dan deret *noise* ARMA (1,1) dengan Penambahan *outlier*

Parameter	Estimasi	SE	t-value	P-value	Outlier
ϕ_1	0,31150	0,04794	6,50	<0,0001	Additive
θ_1	0,88770	0,02400	36,99	<0,0001	Additive
ϖ_0	0,0034051	0,0005774	5,90	<0,0001	Additive
ω_{303}	13,21231	0,86775	15,23	<0,0001	Additive
ω_{650}	12,73093	0,86757	14,67	<0,0001	Additive
ω_{422}	11,41694	0,91450	12,48	<0,0001	Additive
ω_{330}	9,20483	0,86723	10,61	<0,0001	Additive
ω_{616}	8,58383	0,91772	9,35	<0,0001	Additive
ω_{540}	8,41826	0,91788	9,17	<0,0001	Additive
ω_{690}	5,96269	0,86732	6,87	<0,0001	Additive
ω_{489}	5,68205	0,86929	6,54	<0,0001	Additive
ω_{356}	6,60085	0,93249	7,08	<0,0001	Additive
ω_{598}	5,79341	0,86754	6,68	<0,0001	Additive
ω_{557}	5,41948	0,87014	6,23	<0,0001	Additive
ω_{423}	5,71620	0,92331	6,19	<0,0001	Additive
ω_{335}	6,02445	0,91480	6,59	<0,0001	Additive
ω_{350}	4,92605	0,86829	5,67	<0,0001	Additive
ω_{610}	5,01228	0,86784	5,78	<0,0001	Additive
ω_{468}	4,60867	0,86831	5,31	<0,0001	Additive
ω_{588}	4,66883	0,87004	5,37	<0,0001	Additive
ω_{630}	4,75003	0,87422	5,43	<0,0001	Additive
ω_{391}	4,80132	0,86962	5,52	<0,0001	Additive
ω_{104}	4,09427	0,86747	4,72	<0,0001	Additive
ω_{178}	3,96544	0,86692	4,57	<0,0001	Additive
ω_{615}	4,02188	0,91985	4,37	<0,0001	Additive
ω_{541}	3,80671	0,91667	4,15	<0,0001	Additive

Tabel 4.26 Uji Signifikansi Parameter Model Fungsi Transfer ARIMA $([1,12],1,[3,33])$, b, r, s (0,0,0) dan deret *noise* ARMA (1,1) dengan Penambahan *outlier* (Lanjutan)

ω_{172}	3,51554	0,86692	4,06	<0,0001	Additive
ω_{228}	3,17754	0,86732	3,66	0,0003	Additive
ω_{416}	3,44196	0,86858	3,96	<0,0001	Additive
ω_{393}	3,14217	0,86948	3,61	0,0003	Additive
ω_{348}	3,07087	0,87022	3,53	0,0004	Additive
ω_{145}	2,75847	0,86735	3,18	0,0015	Additive
ω_{370}	-2,28566	0,60780	-3,76	0,0002	L. Shift
ω_{400}	2,75614	0,64623	4,26	<0,0001	L. Shift
ω_{358}	4,02748	0,93155	4,32	<0,0001	Additive
ω_{364}	2,82962	0,87283	3,24	0,0012	Additive
ω_{124}	2,74345	0,86779	3,16	0,0016	Additive
ω_{583}	-3,55312	0,70405	-5,05	<0,0001	L. Shift
ω_{579}	2,99990	0,71041	4,22	<0,0001	L. Shift
ω_{334}	2,96710	0,91457	3,24	0,0012	Additive
ω_{401}	2,72851	0,87461	3,12	0,0019	Additive
ω_{274}	-2,64479	0,86750	-3,05	0,0024	Additive
ω_{629}	-1,87903	0,61411	-3,06	0,0023	L. Shift
ω_{357}	3,44963	0,97742	3,53	0,0004	Additive
ω_1	-2,72438	0,59552	-4,57	<0,0001	Additive
ω_{162}	-2,54226	0,86711	-2,93	0,0035	Additive
ω_{334}	2,35703	0,86919	2,71	0,0069	Additive

Tabel 4.25 dan 4.26 menunjukkan parameter-parameter pada model fungsi transfer dengan penambahan *outlier* telah signifikan. Hal tersebut dikarenakan *P-value* yang diperoleh kurang dari α sebesar 0,05. Jenis *outlier* yang terdapat pada data nilai transaksi penjualan saham adalah *additive* dan *level shift*.

Selanjutnya dilakukan pemeriksaan diagnostik residual *white noise* yang tertera pada Tabel 4.27.

Tabel 4.27 Pengujian Asumsi *White Noise* Model Fungsi Transfer dengan Penambahan *Outlier*

Lag	DF	<i>Chi-square</i>	<i>P-value</i>	Lag	DF	<i>Chi-square</i>	<i>P-value</i>
6	4	5,38	0,2502	30	28	30,14	0,3565
12	10	10,93	0,3631	36	34	32,19	0,5564
18	16	15,17	0,5120	42	40	34,49	0,7163
24	22	23,54	0,3717	48	46	36,81	0,8314

Pengujian asumsi residual pada tabel di atas memperlihatkan *P-value* lebih besar dari α (0,05), sehingga dapat dikatakan bahwa asumsi residual *white noise* telah terpenuhi. Selanjutnya dilakukan pengujian normalitas dari residual menggunakan uji Kolmogorov-Smirnov. Berdasarkan uji KS didapatkan nilai Statistik KS sebesar 0,031697 dengan *P-value* sebesar 0,0823, yang artinya residual telah berdistribusi normal.

Berikut adalah persamaan matematis model fungsi transfer antara nilai transaksi penjualan saham dengan IHSG:

Model deret *noise* ARMA (1,1)

$$\eta_t = \frac{(1 - 0,8877B)}{(1 - 0,3115B)} a_t$$

model fungsi transfer dengan deteksi *outlier* yang terbentuk adalah

$$Z_t = \omega_0 X_{1,t} + \eta_t + \varpi_t^{(T_j)}$$

artinya adalah kenaikan nilai transaksi saham pada hari ini sejajar dengan kenaikan IHSG pada hari ini pula. Dengan $Z_t = Z_t - Z_{t-1}$ dan $X_{1,t} = X_{1,t} - X_{1,t-1}$ sehingga model fungsi tranfer yang terbentuk adalah


$$\begin{aligned}
Z_t = & 0,003405X_{1,t} + -0,002345X_{1,t-1} - 0,001061X_{1,t-2} + 0,3115Z_{t-1} \\
& + Z_{t-1} + 0,3115Z_{t-2} + a_t + 0,8877a_{t-1} + 13,212I_t^{303} + 12,73I_t^{650} \\
& + 11,417I_t^{422} + 9,205I_t^{330} + 8,584I_t^{616} + 8,418I_t^{540} + 5,963I_t^{690} \\
& + 5,682I_t^{489} + 6,60I_t^{356} + 5,793I_t^{598} + 5,419I_t^{557} + 5,716I_t^{423} + \\
& + 6,024I_t^{335} + 4,926I_t^{350} + 5,012I_t^{610} + 4,609I_t^{468} + 4,669I_t^{588} \\
& + 4,750I_t^{630} + 4,80I_t^{391} + 4,094I_t^{104} + 3,965I_t^{178} + 4,022I_t^{615} \\
& + 3,806I_t^{541} + 3,516I_t^{172} + 3,178I_t^{228} + 3,442I_t^{416} + 3,142I_t^{393} \\
& + 3,07I_t^{348} + 2,758I_t^{145} - 2,286I_t^{370} + 2,756I_t^{400} + 4,027I_t^{358} \\
& + 2,83I_t^{364} + 2,743I_t^{124} - 3,553I_t^{583} + 2,999I_t^{579} + 2,967I_t^{334} \\
& + 2,729I_t^{401} - 2,665I_t^{274} - 1,879I_t^{629} + 3,45I_t^{357} - 2,724I_t^1 \\
& - 2,542I_t^{162} + 2,357I_t^{344}
\end{aligned}$$

Dari model di atas, diperoleh nilai ramalan *outsample* sebanyak 20 hari atau 1 bulan adanya transaksi penjualan saham di Bursa Efek Indonesia yang tertera pada Tabel 4.28.

Tabel 4.28 Hasil Ramalan *Outsample* Model Fungsi Transfer

waktu ke-t	ramalan	waktu ke-t	ramalan
713	5,398748	723	5,299125
714	5,365469	724	5,311732
715	5,312913	725	5,298973
716	5,310488	726	5,293238
717	5,322843	727	5,299728
718	5,28647	728	5,299783
719	5,275244	729	5,315575
720	5,300553	730	5,339382
721	5,317817	731	5,351041
722	5,328885	732	5,320133

Perbandingan antara data aktual, *fits*, data *outsample* serta nilai ramalan dari model fungsi transfer ditampilkan dalam bentuk plot pada Gambar 4.18.



Gambar 4.18 Time Series Plot antara *Fits*, *Aktual*, *Outsample*, dan *Ramalan* Model Fungsi Transfer

Berdasarkan ramalan yang telah didapatkan dari model fungsi transfer, diperoleh nilai RMSE *insample* sebesar 0,949 dan RMSE *outsample* sebesar 1,77 dengan SMAPE 18,54%. Meninjau dari analisis sebelumnya, jika dibandingkan dengan model ARIMAX, maka model fungsi transfer lebih baik karena nilai kriteria modelnya dari RMSE maupun SMAPE lebih kecil.

4.4 Pengujian Efek ARCH/GARCH pada Residual Model ARIMAX dan Fungsi Transfer.

Setelah diperoleh model ARIMA yang sesuai, untuk langkah selanjutnya dilakukan analisis menggunakan metode GARCH untuk mengetahui residual model memiliki varian yang konstan atau tidak, yang hal ini disebut juga sebagai identifikasi heteroskedastisitas. Langkah pertama yang harus dilakukan adalah melakukan pemeriksaan atau pengujian pada residual model ARIMAX dan model fungsi transfer menggunakan uji *Langrange Multiplier* (Uji *LM*). Pengujian ini dilakukan dengan hipotesis sebagai berikut.

$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_m = 0$ (Tidak terdapat efek ARCH)

$H_1 : \text{minimal ada satu } \theta_j \neq 0, \text{ untuk } j = 1, 2, \dots, m$

Tabel 4.29 Pengujian *Langrange Multiplier* pada Residual Model ARIMAX

Model	Hingga Lag ke-	LM	P-value
(0,1,3)	1	2,9588	0,0854
	2	3,7144	0,1561
	3	6,1666	0,1038
	4	6,8115	0,1462
	5	7,6678	0,1755
	6	7,6678	0,2635
	7	7,7079	0,3591
	8	7,7080	0,4625
	9	7,7751	0,5570
	10	7,7758	0,6507
	11	8,1075	0,7036
	12	9,2491	0,6815
(4,1,[5,11])	1	2,6120	0,1061
	2	3,2333	0,1986
	3	3,5354	0,3162
	4	3,6881	0,4499
	5	3,6937	0,5943
	6	10,6444	0,1000
	7	11,3742	0,1231
	8	11,4066	0,1797
	9	11,4185	0,2481
	10	11,5877	0,3136
	11	11,5912	0,3951
	12	14,3444	0,2793
Fungsi Transfer	1	1,7586	0,1848
	2	1,7796	0,4107
	3	2,0270	0,5668
	4	4,0366	0,4011
	5	4,8577	0,4335
	6	4,9370	0,5519
	7	7,6144	0,3678
	8	7,9196	0,4414
	9	8,0336	0,5308
	10	15,2923	0,1218
	11	17,0870	0,1053
	12	19,8180	0,0706

Berdasarkan tabel 4.29 diketahui bahwa pengujian residual ketiga model ARIMAX tidak mempunyai efek ARCH/GARCH. Hal tersebut didasarkan pada hasil nilai statistik uji LM yang kurang dari $\chi^2_{\alpha;m}$ dan nilai P -value yang lebih besar dari taraf signifikan α (0,05). Dengan demikian, dapat dikatakan bahwa ketiga model ARIMAX mempunyai varian yang homogen atau konstan.

4.5 Pemodelan Nilai Transaksi Penjualan Saham Harian dengan Menggunakan *Neural Network*


Langkah selanjutnya adalah pemodelan nilai transaksi penjualan saham harian dengan menggunakan model *Neural Network*. *Input* yang digunakan untuk pemodelan *neural network* adalah menggunakan variabel yang ada pada model ARIMA dan ARIMAX (model fungsi transfer). Hasil ramalan dari model ARIMA dan fungsi transfer dijadikan sebagai komponen linier. Sedangkan *input* dari model ARIMA dan fungsi transfer dimodelkan dengan MLP (*Multilayer Perceptron*) yang dijadikan komponen non linier. Dalam pemodelan *neural network* untuk nilai transaksi penjualan saham harian pada *hidden layer* digunakan jumlah *neuron* sebanyak satu hingga sepuluh *neuron*.

Model pertama didasarkan pada pemodelan fungsi transfer, *input* yang digunakan adalah Z_{t-1} , Z_{t-2} , X_t dan x_{t-1} . Berikut adalah RMSE model *multilayer perceptron* dengan *input* model fungsi transfer.

Tabel 4.30 RMSE Model *Multilayer Perceptron* dengan *Input* Fungsi Transfer

Jumlah <i>Neuron</i>	RMSE	Jumlah <i>Neuron</i>	RMSE
1	1,6837	6	1,645
2	1,6908	7	1,6987
3	1,7128	8	1,6898
4	1,6452	9	1,6432
5	1,7152	10	1,6762

Berdasarkan Tabel 4.30 diperoleh nilai RMSE terkecil dengan jumlah *neuron* pada *hidden layer* sebanyak 9 *neuron*. Sehingga model *neural network* (fungsi transfer) dipilih dengan jumlah *neuron* sebanyak sembilan pada *hidden layer*.



Gambar 4.19 Arsitektur *Neural Network Input* Fungsi Transfer (4-9-1)

Sehingga didapatkan persamaan matematis untuk model *neural network* dengan *input* model fungsi transfer untuk nilai transaksi penjualan saham harian sebagai berikut

$$Z_{1,t} = -0,084 + 0,261f_1^h(.) - 0,162f_2^h(.) - 0,264f_3^h(.) - 0,615f_4^h(.) - 0,499f_5^h(.) + 0,660f_5^h(.) - 0,002f_7^h(.) + 0,703f_8^h(.) + 0,729f_9^h(.)$$

dengan

$$f_1^h(.) = (1 + \exp(-(-0,481 + 0,347Z_{t-1} + 0,099Z_{t-2} - 0,281X_t + 0,035X_{t-1})))^{-1};$$

$$f_2^h(.) = (1 + \exp(-(-0,213 - 0,250Z_{t-1} + 0,242Z_{t-2} - 0,387X_t - 0,374X_{t-1})))^{-1};$$

$$f_3^h(.) = (1 + \exp(-(-0,209 - 0,139Z_{t-1} - 0,524Z_{t-2} - 0,246X_t + 0,230X_{t-1})))^{-1};$$

$$f_4^h(.) = (1 + \exp(-(-0,796 - 0,277Z_{t-1} - 0,552Z_{t-2} - 0,084X_t + 0,133X_{t-1})))^{-1};$$


$$\begin{aligned}
f_5^h(.) &= (1 + \exp(-(-0,706 - 0,67I_{t-1} + 0,60I_{t-2} - 0,145X_t + 0,06IX_{t-1})))^{-1}; \\
f_6^h(.) &= (1 + \exp(-(-0,463 + 0,46I_{t-1} - 0,48Z_{t-2} - 0,310X_t + 0,142X_{t-1})))^{-1}; \\
f_7^h(.) &= (1 + \exp(-(-0,376 - 0,240I_{t-1} - 0,283I_{t-2} - 0,464X_t - 0,244X_{t-1})))^{-1}; \\
f_8^h(.) &= (1 + \exp(-(-0,764 - 0,796I_{t-1} + 0,36I_{t-2} + 0,386X_t + 0,284X_{t-1})))^{-1}; \\
f_9^h(.) &= (1 + \exp(-(-0,536 + 0,208I_{t-1} + 0,148I_{t-2} + 0,039X_t - 0,01IX_{t-1})))^{-1};
\end{aligned}$$

Untuk model *neural network* kedua didasarkan pada pemodelan ARIMA (4,1,[5,11]). *Input* yang digunakan adalah Z_{t-1} , Z_{t-2} , Z_{t-3} dan Z_{t-4} . Berikut adalah RMSE model *multilayer perceptron* dengan *input* model ARIMA. Dan jumlah *neuron* pada *hidden layer* sebanyak 1 hingga 10 *neuron* pada *hidden layer*.

Tabel 4.31 RMSE Model *Multilayer Perceptron* dengan *Input* ARIMA

Jumlah Neuron di <i>Hidden layer</i>	RMSE	Jumlah Neuron di <i>Hidden layer</i>	RMSE
1	1,7415	6	1,6469
2	1,7164	7	1,6883
3	1,7107	8	1,7077
4	1,6588	9	1,7003
5	1,7036	10	1,7009

Tabel 4.31 menunjukkan nilai RMSE terkecil dengan jumlah *neuron* pada *hidden layer* sebanyak 6 *neuron*. Sehingga dipilih model *neural network* dengan jumlah *neuron* sebanyak enam pada *hidden layer*. Arsitektur dari model *neural network* dengan *input* model ARIMA ditampilkan pada Gambar 4.20.



Gambar 4.20 Arsitektur *Neural Network Input ARIMA* (4-6-1)


Hasil arsitektur di atas, dapat dituliskan menjadi persamaan matematis untuk model *neural network* dengan *input ARIMA* untuk nilai transaksi penjualan saham harian sebagai berikut

$$Z_{2,t} = -0,169 + 0,475f_1^h(.) - 0,477f_2^h(.) - 0,5427f_3^h(.) - 0,190f_4^h(.) \\ - 0,549f_5^h(.) - 0,871f_6^h(.)$$

dengan

$$f_1^h(.) = (1 + \exp(-(0,215 - 0,186Z_{t-1} + 0,76Z_{t-2} - 0,352X_t - 0,289X_{t-1})))^{-1}; \\ f_2^h(.) = (1 + \exp(-(0,311 - 0,347Z_{t-1} + 0,039Z_{t-2} - 0,559X_t - 0,088X_{t-1})))^{-1}; \\ f_3^h(.) = (1 + \exp(-(0,683 - 0,107Z_{t-1} + 0,053Z_{t-2} - 0,101X_t + 1,153X_{t-1})))^{-1}; \\ f_4^h(.) = (1 + \exp(-(0,707 - 0,340Z_{t-1} - 0,077Z_{t-2} + 0,007X_t - 0,169X_{t-1})))^{-1}; \\ f_5^h(.) = (1 + \exp(-(0,868 - 0,472Z_{t-1} - 0,850Z_{t-2} + 0,616X_t - 0,279X_{t-1})))^{-1}; \\ f_6^h(.) = (1 + \exp(-(0,1087 - 1,036Z_{t-1} + 0,565Z_{t-2} - 0,099X_t + 0,231X_{t-1})))^{-1};$$

Perbandingan antara data aktual dan *fits* dari model *neural network inputan* fungsi transfer dan ARIMA ditampilkan dalam bentuk plot pada Gambar 4.21.



Gambar 4.21 a. Time Series Plot antara Fits dan Aktual Model Neural Network Fungsi Transfer, b. Model Neural Network ARIMA


4.5 Perbandingan Model Nilai Transaksi Penjualan Saham Harian

Setelah didapatkan model ARIMAX dan *neural network* yang sesuai untuk meramalkan nilai transaksi penjualan saham selanjutnya dilakukan pemilihan model terbaik berdasarkan *ousample*. Ukuran kriteria yang digunakan adalah RMSE dan SMAPE. Tabel 4.32 merupakan nilai RMSE dan SMAPE dari masing-masing model.

Tabel 4.32 Nilai RMSE dan SMAPE Model-Model Peramalan Nilai Transaksi Penjualan Saham Harian.

Model	<i>Insample</i>	<i>Outsample</i>	
	RMSE _{in}	RMSE _{out}	SMAPE
ARIMAX (0,1,3)	1,3195	1,7928	18,66%
ARIMAX (4,1,[5,11])	1,4383	1,8660	20,05%
Fungsi Transfer	0,9495	1,5000	16,34%
NN ARIMA (4-6-1)	1,6469	1,6365	17,21%
NN Fungsi Transfer (4-9-1)	1,6432	1,7469	16,44%

Berdasarkan tabel 4.32 didapatkan hasil bahwa model dengan hasil peramalan terbaik adalah model fungsi transfer. Hasil ramalan dengan data aktual di ditampilkan pada Gambar Model fungsi transfer untuk nilai transaksi penjualan saham harian dapat dituliskan sebagai berikut.



Gambar 4.22 Time Series Plot antara *Fits* dan Nilai Ramalan Model Fungsi Transfer

Model fungsi transfer untuk nilai transaksi penjualan saham harian dapat dituliskan sebagai berikut.

$$\begin{aligned}
 Z_t = & 0,003405X_{1,t} - 0,002345X_{1,t-1} - 0,00106IX_{1,t-2} + 0,3115Z_{t-1} \\
 & + Z_{t-1} + 0,3115Z_{t-2} + a_t + 0,8877a_{t-1} + 13,212I_t^{303} + 12,731I_t^{650} \\
 & + 11,417I_t^{422} + 9,205I_t^{330} + 8,584I_t^{616} + 8,418I_t^{540} + 5,963I_t^{690} \\
 & + 5,682I_t^{489} + 6,601I_t^{356} + 5,793I_t^{598} + 5,419I_t^{557} + 5,716I_t^{423} + \\
 & + 6,024I_t^{335} + 4,926I_t^{350} + 5,012I_t^{610} + 4,609I_t^{468} + 4,669I_t^{588} \\
 & + 4,750I_t^{630} + 4,801I_t^{391} + 4,094I_t^{104} + 3,965I_t^{178} + 4,022I_t^{615} \\
 & + 3,806I_t^{541} + 3,516I_t^{172} + 3,178I_t^{228} + 3,442I_t^{416} + 3,142I_t^{393} \\
 & + 3,071I_t^{348} + 2,758I_t^{145} - 2,286I_t^{370} + 2,756I_t^{400} + 4,027I_t^{358} \\
 & + 2,83I_t^{364} + 2,743I_t^{124} - 3,553I_t^{583} + 2,9999I_t^{579} + 2,967I_t^{334} \\
 & + 2,729I_t^{401} - 2,665I_t^{274} - 1,879I_t^{629} + 3,45I_t^{357} - 2,724I_t^1 \\
 & - 2,542I_t^{162} + 2,357I_t^{344}
 \end{aligned}$$

Nilai ramalan nilai transaksi saham harian selama setahun kedepan ditampilkan pada Tabel 4.33.

Tabel 4.33 Hasil Ramalan 1 Tahun Kedepan Model Fungsi Transfer

waktu ke-t	ramalan
733	7,753388
734	7,376334
735	7,227175
736	7,164591
737	7,144306
738	7,15933
739	7,183209
740	7,166087
741	7,158537
742	7,175454
743	7,172691
744	7,188867
:	:
815	7,135721
816	7,135722
:	:
929	7,135721
930	7,135721

Berdasarkan hasil ramalan nilai transaksi saham harian dengan model fungsi transfer, didapatkan bahwa ramalan dalam kurun waktu yang panjang menghasilkan ramalan yang konstan. Hal tersebut dimungkinkan karena peramalan dilakukan selama periode yang panjang. Oleh karena itu, diperlukan perbaharuan data nilai transaksi penjualan saham dan prediktor secara berkala agar efek-efek dari prediktor maupun kejadian-kejadian yang tak terduga dapat tertangkap. Dalam kasus ini, efek *outlier* juga sangat berperan pada nilai transaksi penjualan saham harian. Bentuknya dapat berupa *shock event* atau kejadian mendadak seperti perubahan peraturan mengenai perdagangan saham, kebijakan pemerintah maupun kebijakan dari bursa luar negeri.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan pada data nilai transaksi penjualan saham harian di Bursa Efek Indonesia, didapatkan beberapa kesimpulan untuk menjawab tujuan penelitian yaitu:

1. Nilai transaksi penjualan saham di Bursa Efek Indonesia mengalami transisi atau perubahan yang meningkat pada tahun 2013 dan 2014. Hal tersebut dikarenakan terdapat penerapan sesi *pre-closing* dan *post-trading* tahun 2013 serta perubahan parameter perdagangan *lot size* atau *tick price* di tahun 2014. Nilai transaksi jual beli saham memiliki transaksi yang relatif sama pada hari Senin hingga Jumat, begitu pula pada setiap minggunya. Kejadian-kejadian ekstrim yang memberikan kaitan yang paling besar pada nilai transaksi jual beli saham di BEI adalah kejadian mengenai perubahan jam perdagangan saham serta perubahan jumlah lot dan kelompok fraksi saham
2. Model yang sesuai untuk meramalkan nilai transaksi penjualan saham harian adalah model fungsi transfer ARIMA $([1,12],1,[3,33])$, b, r, s (0,0,0) dan deret *noise* ARMA (1,1), model ini memberikan nilai SMAPE sebesar 16,34% dan RMSE sebesar 1,50.
3. Hasil ramalan nilai transaksi saham harian dipengaruhi oleh prediktor IHSG, faktor-faktor lain yang memberikan efek terhadap nilai transaksi jual beli saham bentuknya dapat berupa kajadian tak terduga (2 Januari 2012, 27 Agustus 2012, 30 November 2012), kebijakan peraturan baru (25 Maret 2013, 6 Januari 2014), kebijakan pemerintah (31 Mei 2013) dan kebijakan bursa luar negeri (10 Mei 2013, 18 September 2013, 24 dan 27 Desember 2013).

5.2 Saran

Saran untuk penelitian-penelitian selanjutnya berdasarkan penelitian yang telah dilakukan adalah

1. Pemodelan data nilai transaksi penjualan saham harian mempertimbangkan banyak faktor-faktor yang berpengaruh. Dan setiap waktu atau setiap tahun pengaruh dari *series* nilai penjualan saham berbeda, sehingga diperlukan identifikasi secara tepat dan sempurna faktor-faktor tersebut. Oleh karena itu, penggunaan dan penambahan prediktor-prediktor lain seperti indeks LQ45.
2. Penelitian selanjutnya diperlukan penggunaan metode lain untuk meramalkan nilai transaksi saham harian, dengan metode lain akan banyak dibandingkan model satu dengan yang lain untuk diperoleh hasil yang paling baik.

DAFTAR PUSTAKA

- Bowerman, B. L. and O'Connell, R. T. (1993), *Forecasting and Time Series: An Applied Approach*, 3rd edition, California : Duxbury Press.
- Bhudani, N., C. K. Jha, & S. K. Budhani. (2012). Application of Neural Network in Analysis of Stock Market Prediction. *International Journal of Computer Science & Engineering Technology*, 3(4), 61-68.
- Bursa Efek Indonesia. (2015, Februari 25). *Tata Kelola Perusahaan Bursa Efek Indonesia*. Retrieved from <http://www.idx.co.id/id-id/beranda/tentangbei/tatakelolaperusahaan.aspx>
- Bursa Efek Indonesia. (2015, Februari 25). *Sejarah Bursa Efek Indonesia*. Retrieved from <http://www.idx.co.id/id-id/beranda/tentangbei/sejarah.aspx>
- Bursa Efek Indonesia. (2015, Februari 25). *Visi Misi Bursa Efek Indonesia*. Retrieved from <http://www.idx.co.id/idid/beranda/tentangbei/visimisi.aspx>
- Chen, A., Leung, M., & Daouk, H. (2003). Application of Neural Networks to an Emerging Financial Market: Forecasting and Trading The Taiwan Stock Index. *Computers and Operations Research*, 30, 901–923.
- Cryer, J. D. (1986). *Time Series Analysis*. Boston : Publishing Comp.
- Daniel, W. W. (1989). *Statistika Nonparametrik Terapan*. Jakarta : PT. Gramedia.
- De Gooijer, Jan G., & Hyndman, Rob J. (2006). 25 Years of Time Series Forecasting. *International Journal of Forecasting*, 22, 443-473.
- Demirguc-Kunt, A. & R. Levine. (1996). Stock Markets, Corporate Finance, and Economic Growth: An Overview. *The World Bank Economic Review*, 10(2), 223-229.

- Djojonegoro, S., Suhartono & Dewi, D. R. S. (2008). *Pemodelan ARIMAX dan Neural Network untuk Peramalan dan Dasar Perencanaan Investasi Net Aset Value (NAV) Equity di PT. Prudential Life Assurance. Widya Teknik*, 7(1), 90-101.
- Gujarati, D. N. (2004). *Basic Econometrics*, 4th edition. New York : McGraw-Hill Comp.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*, 2nd edition, Oxford : Prentice-Hall.
- Husnan, Suad. 2001. *Dasar-Dasar Teori Portofolio dan Analisis Sekuritas*. Edisi Ketiga, Yogyakarta : Unit Penerbit dan Percetakan AMP YKPN.
- Joanes, D. N., & C. A. Gill. (1998). Comparing Measures of Sample Skewness and Kurtosis". *Journal of the Royal Statistical Society (Series D): The Statistician* 47 (1), 183–189.
- Jogiyanto. (2010). *Studi Peristiwa: Menguji Reaksi Pasar Modal Akibat Suatu Peristiwa*. Edisi Pertama. Yogyakarta : BPFE Yogyakarta.
- Levine, R. and A. Zervos. (1998). Stock Markets, Banks, and Economic Growth. *American Economic Review*, 88(3), 537-58.
- Liang, J, Wei Song, and Mei Wang. (2011). Stock Price Prediction Based on Procedural Neural Networks. *Advances in Artificial Neural Systems*, 6, 1-11.
- Ma'rufah, N., Rahayu, S. P. & Suhartono. (2013). Peramalan Pendapatan Operasional Bank Menggunakan Metode Fungsi Transfer dan Neural Network. *Jurnal Saints dan Seni Pomits*, 2(2), 2337-3520.
- Makridakis, W., Mc Gee. (1999). *Metode dan Aplikasi Peramalan*. Edisi kedua. Jakarta : Bina Rupa Aksara.
- Makridakis, S., Wheelwright, S.C. dan McGee, V.E. (1999). *Metode dan Aplikasi Peramalan*. Terj. Untung Sus Andriyanti dan Abdul Basith. Jakarta: Erlangga.

- Mostafa, Mohamed M. (2010). Forecasting Stock Exchange Movements Using Neural Networks: Empirical Evidence from Kuwait. *Expert Systems with Applications*, 37, 6302-6309.
- Ripley, B. D. (1996). *Pattern Recognition and Neural Networks*. Cambridge : Cambridge University Press.
- Saad, E. W., D. V. Prokhorov, & Donald C. Wunsch. (1998). Comparative Study of Stock Trend Prediction Using Time Delay, Recurrent and Probabilistic Neural Networks. *IEEE Transactions on Neural Networks*, 9(6), 1456-1470.
- Sarle, W. (1994). Neural Network and Statistical Models. In *Proceeding 19th A SAS Users Group Int. Conf.*, 1538-1550.
- Singh A. (1996). Financial Liberalisation, Stockmarkets and Economic Development. *The Economic Journal*, 107, 771-782.
- Suhartono. (2008). New Procedures for Model Selection in Feedforward Neural Networks for Time Series Forecating. *Jurnal Ilmu Dasar*, 9(2), 104–113.
- Suhartono. (2007). *Feedforward Neural Networks untuk Pemodelan Runtun Waktu*. Disertasi, Yogyakarta : Universitas Gadjah Mada.
- Suhartono and Lee, M.H. (2011). Forecasting of Tourist Arrivals Using Subset, Multiplicative or Additive Seasonal Arima Model. *Matematika*, 27(2), 169-182.
- Tsay, Ruey. (2002). *Analysis of Financial Time Series*. Canada : John Wiley & Sons, Inc.
- Walpole, R.E. (1995). *Pengantar Statistika*. Jakarta : PT. Gramedia Pustaka Utama.
- Wei, W.W.S. (2006). *Time Series Analysis, Univariate and Multivariate Methods*. Canada: Addison Wesley Publishing Company.

~Halaman ini sengaja dikosongkan~

LAMPIRAN A. Data Nilai Transaksi Penjualan Saham Harian
Periode Tahun 2012 Hingga Tahun 2014.

Tanggal	IHSG	Nilai Transaksi (Dalam Triliyun)
2-Jan-12	3809,140	1,102228
3-Jan-12	3857,882	3,534932
4-Jan-12	3907,421	4,805590
5-Jan-12	3906,264	3,672567
6-Jan-12	3869,415	3,330106
9-Jan-12	3889,072	3,755654
:	:	:
26-Dec-12	4275,094	3,405723
27-Dec-12	4281,861	4,500419
28-Dec-12	4316,687	5,573997
2-Jan-13	4346,475	4,718022
3-Jan-13	4399,258	6,350951
4-Jan-13	4410,020	5,109318
:	:	:
24-Dec-13	4202,834	2,637933
27-Dec-13	4212,980	9,412147
30-Dec-13	4274,177	4,197794
2-Jan-14	4327,265	3,341498
3-Jan-14	4257,663	3,353071
6-Jan-14	4202,809	3,111905
:	:	:
23-Dec-14	5139,068	6,809766
24-Dec-14	5166,983	9,299883
29-Dec-14	5178,373	5,001116
30-Dec-14	5226,947	9,109381

LAMPIRAN B. Syntax SAS untuk Pemodelan Data Nilai Transaksi Penjualan Saham Harian.

1. Syntax SAS Model ARIMA (0,1,3).

```
data Transaksi;
input zt;
datalines;
0.974062
0.711111
0.654528
:
0.629758
;
/* Proses Identifikasi */
proc arima data=Transaksi;
identify var=zt(1);
run;
/* Proses Estimasi */
estimate q=3 noconstant method=cls;
run;
/* Proses Forecasting*/
forecast out=ramalan lead=25;
run;
/* Proses Identifikasi Outlier*/
outlier maxnum=30 alpha=0.00135;
proc print data=ramalan;
run;
/* Proses Uji Normal*/
proc univariate data=ramalan normal;
var residual;
run;
```

2. Syntax SAS Model ARIMA (4,1,[5]).

```
data Transaksi;
input zt;
datalines;
0.974062
:
```



```

:
0.629758
;
/* Proses Identifikasi */
proc arima data=Transaksi;
identify var=zt(1);
run;
/* Proses Estimasi */
estimate p=4 q=(5) noconstant method=cls;
run;
/* Proses Forecasting*/
forecast out=ramalan lead=25;
run;
/* Proses Identifikasi Outlier*/
outlier maxnum=30 alpha=0.00135;
proc print data=ramalan;
run;
/* Proses Uji Normal*/
proc univariate data=ramalan normal;
var residual;
run;

```

3. Syntax SAS Model ARIMA (0,1,3) dengan Penambahan *Outlier* dan Pengujian Efek ARCH/GARCH.

```

data Transaksi;
input zt;
datalines;
0.974062
0.711111
:
0.629758
;
data Transaksi;
set Transaksi;
  if _n_=162 then AONUM1 =1; else AONUM1 =0;
  if _n_=1 then AONUM2 =1; else AONUM2 =0;
  if _n_=650 then AONUM3 =1; else AONUM3=0;
:

```

```

if _n_=422 then AONUM14 =1; else AONUM14=0;
if _n_=468 then AONUM15 =1; else AONUM15=0;
if _n_=690 then AONUM16 =1; else AONUM16=0;
run;
/* Proses Identifikasi */
proc arima data=Transaksi;
  identify var=zt(1) crosscorr=(AONUM1(1) AONUM2(1)
    AONUM3(1) AONUM4(1) AONUM5(1) AONUM6(1)
    AONUM7(1) AONUM8(1) AONUM9(1) AONUM10(1)
    AONUM11(1) AONUM12(1) AONUM13(1) AONUM14(1)
    AONUM15(1) AONUM16(1) ) noprint;
/* Proses Estimasi */
estimate q=3 input=(AONUM1 AONUM2 AONUM3 AONUM4
  AONUM5 AONUM6 AONUM7 AONUM8 AONUM9
  AONUM10 AONUM11 AONUM12 AONUM13
  AONUM14 AONUM15 AONUM16) noconstant
  method=cls;
/* Proses Forecasting */
forecast out=ramalan lead=20;
run;
proc print data=ramalan;
run;
/* Proses Uji Normal */
proc univariate data=ramalan normal;
var residual;
run;
/* Proses Uji ARCH/GARCH */
proc autoreg data=ramalan;
model residual=/archtest noint;
model residual=/noint garch = (q=1,p=1);
output out=resi cev=vhat ;
run;
proc print data=resi;
run;
proc export data=work.ramalan
outfile="E:\ramalan.xls" dbms=excel97 replace;
sheet="1";
run;

```

4. Syntax SAS Model ARIMA (4,1,[5,11]) dengan Penambahan *Outlier* Pengujian Efek ARCH/GARCH

```

data Transaksi;
input zt;
datalines;
0.974062
0.711111
:
0.629758
;
data Transaksi;
set Transaksi;
  if _n_=162 then AONUM1 =1; else AONUM1 =0;
  if _n_=1 then AONUM2 =1; else AONUM2 =0;
  if _n_=650 then AONUM3 =1; else AONUM3=0;
  if _n_=489 then AONUM4 =1; else AONUM4=0;
  if _n_=598 then AONUM5 =1; else AONUM5 =0;
  if _n_=303 then AONUM6 =1; else AONUM6=0;
  if _n_=110 then AONUM7 =1; else AONUM7=0;
  if _n_=391 then AONUM8 =1; else AONUM8=0;
  if _n_=274 then AONUM9 =1; else AONUM9=0;
  if _n_=690 then AONUM10 =1; else AONUM10=0;
run;
/* Proses Identifikasi */
proc arima data=Transaksi;
  identify var=zt(1) crosscorr=(AONUM1(1) AONUM2(1)
    AONUM3(1) AONUM4(1) AONUM5(1) AONUM6(1)
    AONUM7(1) AONUM8(1) AONUM9(1) AONUM10(1))
  noprint;
/* Proses Estimasi */
estimate p=4 q=(5,11) input=(AONUM1 AONUM2 AONUM3
  AONUM4 AONUM5 AONUM6 AONUM7 AONUM8
  AONUM9 AONUM10) noconstant method=cls;
/* Proses Forecasting */
forecast out=ramalan lead=20;
run;
proc print data=ramalan;
run;
/* Proses Uji Normal */

```

```

proc univariate data=ramalan normal;
var residual;
run;
/* Proses Uji ARCH/GARCH */
proc autoreg data=ramalan;
model residual=/archtest noint;
model residual=/noint garch = (q=1,p=1);
output out=resi cev=vhat ;
run;
proc print data=resi;
run;
proc export data=work.ramalan
outfile="E:\ramalan.xls" dbms=excel97 replace;
sheet="2";
run;

```

5. Syntax SAS Model Fungsi Transfer dan Pengujian Efek ARCH/GARCH.

```

data transaksi;
input zt ihsg;
datalines;
1.1022279      3809.140
3.5349324      3857.882
4.8055902      3907.421
:              :
4.7176348      5145.315
5.5437334      5149.888
;
data transaksi;
set transaksi;
  if _n_=303 then AONUM1 =1; else AONUM1 =0;
  if _n_=650 then AONUM2 =1; else AONUM2 =0;
  if _n_=422 then AONUM3 =1; else AONUM3 =0;
  if _n_=330 then AONUM4 =1; else AONUM4 =0;
  :
  if _n_>=370 then LSNUM30 =1; else LSNUM30=0;
  if _n_>=400 then LSNUM31 =1; else LSNUM31=0;
  :

```

```

        if _n_=162 then AONUM43 =1; else AONUM43=0;
        if _n_=344 then AONUM44 =1; else AONUM44=0;
run;
proc arima data=transaksi;
/*--- Proses Input -----*/
identify var=ihsg(1);
run;
/*--- Estimasi Model Input -----*/
estimate p=(1,12) q=(3,33) noconstant method=cls plot;
run;
/*--- Crosscorrelation of prewhitened series -----*/
identify var=zt(1) crosscorr=(ihsg(1) AONUM1(1) AONUM2(1)
    AONUM3(1) AONUM4(1) AONUM5(1) AONUM6(1)
    AONUM7(1) AONUM8(1) AONUM9(1) AONUM10(1)
    AONUM11(1) AONUM12(1) AONUM13(1) AONUM14(1)
    AONUM15(1) AONUM16(1) AONUM17(1) AONUM18(1)
    AONUM19(1) AONUM20(1) AONUM21(1) AONUM22(1)
    AONUM23(1) AONUM24(1) AONUM25(1) AONUM26(1)
    AONUM27(1) AONUM28(1) AONUM29(1) LSNUM30(1)
    LSNUM31(1) AONUM32(1) AONUM33(1) AONUM34(1)
    LSNUM35(1) LSNUM36(1) AONUM37(1) AONUM38(1)
    AONUM39(1) LSNUM40(1) AONUM41(1) AONUM42(1)
    AONUM43(1) AONUM44(1)) ;
run;
/*--- Estimasi Model Fungsi Transfer -----*/
estimate p=1 q=1 input=( 0 $ ihsg AONUM1 AONUM2
    AONUM3 AONUM4 AONUM5 AONUM6 AONUM7
    AONUM8 AONUM9 AONUM10 AONUM11 AONUM12
    AONUM13 AONUM14 AONUM15 AONUM16 AONUM17
    AONUM18 AONUM19 AONUM20 AONUM21 AONUM22
    AONUM23 AONUM24 AONUM25 AONUM26
    AONUM27 AONUM28 AONUM29 LSNUM30 LSNUM31
    AONUM32 AONUM33 AONUM34 LSNUM35 LSNUM36
    AONUM37 AONUM38 AONUM39 LSNUM40 AONUM41
    AONUM42 AONUM43 AONUM44 ) noconstant
    method=cls plot;
run;

/*--- Forecasting-----*/

```

```
forecast lead=20 out=ramalan;
run;
proc print data=ramalan;
run;
/*--- Uji Normal-----*/
proc univariate data=ramalan normal;
var residual;
run;
/* Proses Uji ARCH/GARCH */
proc autoreg data=ramalan;
model residual=/archtest noint;
model residual=/noint garch = (q=1,p=1);
output out=resi cev=vhat ;
run;
proc print data=resi;
run;
proc export data=work.ramalan
outfile="E:\ramalan.xls" dbms=excel97 replace;
sheet="3";
run;
```

LAMPIRAN C. Output SAS untuk Pemodelan ARIMAX Data Nilai Transaksi Penjualan Saham Harian.

1. Output SAS Model ARIMA (4,1,[5]).

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.14550		0.04752	3.06	0.0023	5			
AR1,1	-0.51546		0.03732	-13.81	<.0001	1			
AR1,2	-0.40522		0.04154	-9.75	<.0001	2			
AR1,3	-0.39659		0.04302	-9.22	<.0001	3			
AR1,4	-0.27037		0.04526	-5.97	<.0001	4			
Variance Estimate				0.002031					
Std Error Estimate				0.045069					
AIC				-2384.87					
SBC				-2362.04					
Number of Residuals				711					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.15	1	0.2837	0.007	0.001	-0.004	-0.009	0.001	-0.038
12	2.59	7	0.9199	-0.007	-0.022	0.012	-0.011	-0.028	-0.021
18	4.44	13	0.9855	-0.026	-0.038	0.013	-0.013	-0.008	-0.007
24	9.50	19	0.9641	0.036	0.069	0.008	0.008	0.019	-0.020
30	17.42	25	0.8658	0.030	-0.049	0.020	-0.073	-0.039	0.014
36	18.81	31	0.9580	-0.006	0.023	-0.012	-0.023	-0.007	0.024
42	21.80	37	0.9779	-0.004	-0.042	-0.004	0.027	0.019	-0.032
48	22.84	43	0.9951	-0.008	0.011	-0.004	-0.003	-0.032	-0.011
Outlier Detection Summary									
Maximum number searched				30					
Number found				20					
Significance used				0.00135					
Outlier Details									
Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq					
162	Additive	0.27667	74.22	<.0001					
1	Additive	0.27638	57.66	<.0001					
650	Additive	-0.18121	32.68	<.0001					
489	Additive	-0.16010	25.39	<.0001					
598	Additive	-0.13872	19.29	<.0001					
303	Additive	-0.13503	18.28	<.0001					
110	Additive	0.12868	16.86	<.0001					
391	Additive	-0.12377	15.85	<.0001					
274	Additive	0.12308	15.85	<.0001					
690	Additive	-0.11531	13.81	0.0002					
468	Additive	-0.11424	13.65	0.0002					
104	Additive	-0.11342	13.46	0.0002					
330	Additive	-0.11316	13.52	0.0002					
422	Additive	-0.11275	13.44	0.0002					
610	Additive	-0.10953	12.81	0.0003					
172	Additive	-0.10883	12.66	0.0004					
178	Additive	-0.10665	12.22	0.0005					
616	Additive	-0.10456	11.85	0.0006					
423	Additive	-0.10338	11.58	0.0007					
145	Additive	-0.10177	11.27	0.0008					

Tests for Normality					
Test	--Statistic--		----p Value-----		
Shapiro-Wilk	W	0.946375	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.065988	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.930294	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	6.072819	Pr > A-Sq	<0.0050	

2. Output SAS Model ARIMA (0,1,3).

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.50040	0.03744	13.36	<.0001	1				
MA1,2	0.13540	0.04160	3.25	0.0012	2				
MA1,3	0.08874	0.03744	2.37	0.0181	3				
Variance Estimate			0.002041						
Std Error Estimate			0.045178						
AIC			-2383.43						
SBC			-2369.73						
Number of Residuals			711						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.07	3	0.0696	-0.005	-0.016	-0.044	0.019	0.081	0.028
12	8.65	9	0.4698	0.006	-0.038	0.016	0.011	-0.007	-0.017
18	10.53	15	0.7850	-0.026	-0.030	0.025	-0.007	-0.012	-0.015
24	14.98	21	0.8238	0.030	0.067	0.006	-0.002	0.008	-0.023
30	23.51	27	0.6571	0.041	-0.039	0.022	-0.077	-0.039	0.018
36	25.40	33	0.8252	-0.001	0.019	-0.024	-0.029	-0.006	0.026
42	28.73	39	0.8846	-0.006	-0.047	-0.008	0.025	0.021	-0.034
48	29.57	45	0.9631	-0.015	0.004	-0.004	0.004	-0.026	-0.007
Outlier Detection Summary									
Maximum number searched			30						
Number found			21						
Significance used			0.00135						
Outlier Details									
Obs	Type	Estimate	Chi-Square	Approx Prob > ChiSq					
162	Additive	0.28312	74.49	<.0001					
1	Additive	0.27923	57.52	<.0001					
650	Additive	-0.18118	31.23	<.0001					
489	Additive	-0.16358	25.79	<.0001					
598	Additive	-0.13282	17.09	<.0001					
303	Additive	-0.13275	17.17	<.0001					
391	Additive	-0.12468	15.25	<.0001					
274	Additive	0.12356	15.22	<.0001					
330	Additive	-0.12086	14.85	0.0001					
104	Additive	-0.12007	14.92	0.0001					
610	Additive	-0.11969	14.97	0.0001					
110	Additive	0.11802	14.73	0.0001					
172	Additive	-0.11706	15.01	0.0001					
422	Additive	-0.11606	14.96	0.0001					
468	Additive	-0.11524	14.78	0.0001					
690	Additive	-0.11241	14.63	0.0001					
145	Additive	-0.10173	11.98	0.0005					
178	Additive	-0.10136	11.89	0.0006					
423	Additive	-0.10111	11.91	0.0006					
616	Additive	-0.09774	11.28	0.0008					
540	Additive	-0.09440	10.48	0.0012					

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.945703	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.065699	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.925048	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	5.980765	Pr > A-Sq	<0.0050	

3. Output SAS Model ARIMAX (4,1,[5]).

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift		
MA1,1	0.25481	0.05011	5.09	<.0001	5	zt		0	
AR1,1	-0.54646	0.03796	-14.39	<.0001	1	zt		0	
AR1,2	-0.44700	0.04241	-10.54	<.0001	2	zt		0	
AR1,3	-0.50720	0.04265	-11.89	<.0001	3	zt		0	
AR1,4	-0.34171	0.04680	-7.30	<.0001	4	zt		0	
NUM1	0.27821	0.03356	8.29	<.0001	0	AONUM1		0	
NUM2	0.28131	0.02669	10.54	<.0001	0	AONUM2		0	
NUM3	-0.18402	0.03361	-5.47	<.0001	0	AONUM3		0	
NUM4	-0.15980	0.03376	-4.73	<.0001	0	AONUM4		0	
NUM5	-0.13965	0.03351	-4.17	<.0001	0	AONUM5		0	
NUM6	-0.13387	0.03351	-3.99	<.0001	0	AONUM6		0	
NUM7	0.13125	0.03358	3.91	0.0001	0	AONUM7		0	
NUM8	-0.12465	0.03363	-3.71	0.0002	0	AONUM8		0	
NUM9	0.12662	0.03353	3.78	0.0002	0	AONUM9		0	
NUM10	-0.11473	0.03350	-3.42	0.0007	0	AONUM10		0	
Variance Estimate				0.001426					
Std Error Estimate				0.037766					
AIC				-2626.4					
SBC				-2557.9					
Number of Residuals				711					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.54	1	0.1112	0.017	0.013	-0.020	-0.034	0.002	-0.039
12	17.24	7	0.0159	-0.050	-0.041	-0.004	-0.016	-0.098	-0.080
18	20.90	13	0.0749	-0.004	0.038	0.017	-0.041	-0.015	-0.036
24	24.09	19	0.1927	0.011	0.054	-0.016	-0.011	0.029	-0.000
30	29.36	25	0.2493	0.022	-0.061	0.019	-0.046	-0.005	-0.019
36	31.89	31	0.4221	-0.012	-0.035	-0.026	-0.023	-0.011	0.025
42	34.00	37	0.6105	0.023	0.004	0.045	0.000	0.015	0.003
48	36.96	43	0.7296	-0.002	0.021	-0.012	0.012	-0.052	-0.021

4. Output SAS Model ARIMAX (4,1,[5,11]).

Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift	
MA1,1	0.31503	0.05043	6.25	<.0001	5	zt		0
MA1,2	0.12567	0.03726	3.37	0.0008	11	zt		0
AR1,1	-0.56834	0.03748	-15.16	<.0001	1	zt		0
AR1,2	-0.48196	0.04155	-11.60	<.0001	2	zt		0
AR1,3	-0.55092	0.04257	-12.94	<.0001	3	zt		0
AR1,4	-0.38914	0.04784	-8.13	<.0001	4	zt		0
NUM1	0.28611	0.03345	8.55	<.0001	0	AONUM1		0
NUM2	0.28539	0.02460	11.63	<.0001	0	AONUM2		0
NUM3	-0.18754	0.03349	-5.60	<.0001	0	AONUM3		0
NUM4	-0.16480	0.03365	-4.90	<.0001	0	AONUM4		0
NUM5	-0.13249	0.03337	-3.97	<.0001	0	AONUM5		0
NUM6	-0.13298	0.03337	-3.98	<.0001	0	AONUM6		0
NUM7	0.14405	0.03346	4.30	<.0001	0	AONUM7		0
NUM8	-0.12398	0.03346	-3.71	0.0002	0	AONUM8		0
NUM9	0.12785	0.03342	3.83	0.0001	0	AONUM9		0
NUM10	-0.10295	0.03339	-3.08	0.0021	0	AONUM10		0
Variance Estimate				0.001408				
Std Error Estimate				0.037529				
AIC				-2634.38				
SBC				-2561.32				
Number of Residuals				711				
* AIC and SBC do not include log determinant.								
Autocorrelation Check of Residuals								
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----				
6		0	0.025	0.031	-0.004	-0.033	0.007	-0.050
12	12.38	6	0.0540	-0.059	-0.038	0.001	-0.015	0.009
18	15.48	12	0.2161	-0.003	0.040	0.005	-0.008	-0.031
24	17.67	18	0.4773	0.004	0.047	-0.015	-0.016	0.016
30	23.01	24	0.5193	0.025	-0.060	0.015	-0.047	-0.014
36	26.17	30	0.6664	-0.011	-0.039	-0.034	-0.029	-0.008
42	27.50	36	0.8444	0.016	-0.002	0.036	-0.001	0.012
48	29.48	42	0.9275	-0.005	0.012	-0.008	0.015	-0.041
Tests for Normality								
Test	--Statistic--			----p Value----				
Shapiro-Wilk	W	0.990785	Pr < W	0.0002				
Kolmogorov-Smirnov	D	0.03304	Pr > D	0.0587				
Cramer-von Mises	W-Sq	0.175794	Pr > W-Sq	0.0110				
Anderson-Darling	A-Sq	1.251702	Pr > A-Sq	<0.0050				

5. Output SAS Model ARIMAX (0,1,3).

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift		
MA1,1	0.50714	0.03782	13.41	<.0001	1	zt		0	
MA1,2	0.14935	0.04247	3.52	0.0005	2	zt		0	
MA1,3	0.18806	0.03789	4.96	<.0001	3	zt		0	
NUM1	0.28737	0.03207	8.96	<.0001	0	ANUM1		0	
NUM2	0.29250	0.02293	12.76	<.0001	0	ANUM2		0	
NUM3	-0.18605	0.03213	-5.79	<.0001	0	ANUM3		0	
NUM4	-0.16494	0.03216	-5.13	<.0001	0	ANUM4		0	
NUM5	-0.13562	0.03204	-4.23	<.0001	0	ANUM5		0	
NUM6	-0.13326	0.03201	-4.16	<.0001	0	ANUM6		0	
NUM7	-0.12113	0.03209	-3.78	0.0002	0	ANUM7		0	
NUM8	0.12267	0.03204	3.83	0.0001	0	ANUM8		0	
NUM9	-0.11411	0.03221	-3.54	0.0004	0	ANUM9		0	
NUM10	-0.11357	0.03207	-3.54	0.0004	0	ANUM10		0	
NUM11	-0.12217	0.03203	-3.81	0.0001	0	ANUM11		0	
NUM12	0.12329	0.03208	3.84	0.0001	0	ANUM12		0	
NUM13	-0.11980	0.03202	-3.74	0.0002	0	ANUM13		0	
NUM14	-0.11026	0.03205	-3.44	0.0006	0	ANUM14		0	
NUM15	-0.10995	0.03216	-3.42	0.0007	0	ANUM15		0	
NUM16	-0.11108	0.03202	-3.47	0.0006	0	ANUM16		0	
Variance Estimate				0.001302					
Std Error Estimate				0.036086					
AIC				-2687.18					
SBC				-2600.41					
Number of Residuals				711					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.31	3	0.2302	-0.002	-0.006	-0.005	0.012	0.064	0.041
12	11.98	9	0.2146	-0.006	-0.032	0.014	0.029	-0.044	-0.081
18	18.42	15	0.2411	0.007	0.022	0.043	-0.048	-0.027	-0.058
24	23.08	21	0.3398	0.022	0.030	-0.031	-0.048	0.029	-0.030
30	30.06	27	0.3114	0.034	-0.063	-0.013	-0.030	-0.049	-0.028
36	32.93	33	0.4706	0.001	-0.035	-0.016	-0.036	-0.002	0.032
42	33.52	39	0.7174	0.006	0.004	0.022	0.014	-0.005	-0.005
48	35.93	45	0.8307	0.005	-0.007	-0.005	0.010	-0.053	-0.013
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.995087		Pr < W	0.0226				
Kolmogorov-Smirnov	D	0.032722		Pr > D	0.0643				
Cramer-von Mises	W-Sq	0.101475		Pr > W-Sq	0.1094				
Anderson-Darling	A-Sq	0.678437		Pr > A-Sq	0.0801				

LAMPIRAN D. *Output SAS untuk Pemodelan Fungsi Transfer Data Nilai Transaksi Penjualan Saham Harian.*

1. *Output Prewhitening Model Deret Input IHSG.*

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.13172	0.03695	3.57	0.0004	3
MA1,2	0.13766	0.03754	3.67	0.0003	33
AR1,1	0.07791	0.03749	2.08	0.0380	1
AR1,2	0.09333	0.03746	2.49	0.0129	12

Variance Estimate2126.577

Std Error Estimate46.11482

AIC7469.592

SBC7487.859

Number of Residuals711

* AIC and SBC do not include log determinant.

Correlations of Parameter Estimates

Parameter	MA1,1	MA1,2	AR1,1	AR1,2
MA1,1	1.000	-0.019	-0.019	0.028
MA1,2	-0.019	1.000	-0.071	0.023
AR1,1	-0.019	-0.071	1.000	0.044
AR1,2	0.028	0.023	0.044	1.000

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.63	2	0.0988	0.007	-0.040	0.010	-0.051	0.024	-0.039
12	10.88	8	0.2085	0.044	0.034	0.023	0.052	-0.049	-0.001
18	18.86	14	0.1702	-0.049	-0.018	-0.072	0.007	-0.053	-0.014
24	29.96	20	0.0706	0.035	-0.003	0.013	-0.044	-0.101	0.038
30	37.22	26	0.0713	0.082	0.033	0.032	-0.004	0.030	-0.002
36	43.68	32	0.0817	-0.012	-0.069	0.015	0.044	0.032	-0.024
42	50.63	38	0.0825	0.064	-0.011	-0.044	0.017	0.016	0.050
48	56.99	44	0.0905	-0.036	-0.003	-0.028	0.048	-0.015	-0.060

Crosscorrelation Check Between Series

To Lag	Chi-Square	DF	Pr > ChiSq	-----Crosscorrelations-----					
5	8.93	6	0.1776	0.076	0.002	-0.033	-0.054	0.011	0.052
11	3.49	12	0.6604	-0.007	0.005	-0.010	-0.009	0.023	0.001
17	25.48	18	0.1123	-0.054	-0.056	0.043	0.069	-0.081	0.058
23	27.27	24	0.2919	-0.035	0.011	0.028	-0.018	0.003	-0.005

2. Crosscorrelation Function Deret Input IHSG dan Deret Output Nilai Transaksi Jual Beli Saham.

Crosscorrelations			
Lag	Covariance	Correlation	-1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
-24	0.213854	0.00721	
-23	2.271045	0.02347	
-22	0.345565	0.00357	
-21	-5.066747	-0.5236	
-20	4.237283	0.04379	
-19	2.462003	0.02544	
-18	0.856654	0.00879	
-17	-6.129479	-0.6325	
-16	6.133712	0.06325	
-15	+1.610954	-0.1645	
-14	-9.502940	-0.0708	
-13	7.567161	0.07821	
-12	-3.372774	-0.0406	
-11	2.028053	0.02996	
-10	2.531582	0.03616	
-9	+1.477781	-0.01527	
-8	-9.174433	-0.09402	
-7	4.468738	0.04618	
-6	-2.533356	-0.02618	
-5	2.080934	0.02151	
-4	-0.272669	-0.00282	
-3	6.018220	0.06220	
-2	-3.466296	-0.03520	
-1	2.743029	0.02941	
0	7.320668	0.07579	
1	0.170203	0.00176	
2	-3.156397	-0.03263	
3	-5.248009	-0.05424	
4	1.025064	0.01608	
5	5.020640	0.05188	
6	-0.652684	-0.00676	
7	0.450116	0.00465	
8	-0.577811	-0.01011	
9	-0.873939	-0.00909	
10	2.244881	0.02329	
11	0.139649	0.00144	
12	-5.201358	-0.05376	
13	-5.414612	-0.05596	
14	4.145586	0.04284	
15	6.688384	0.06312	
16	-7.811649	-0.08073	
17	5.583202	0.05770	
18	-3.472609	-0.03537	
19	1.106383	0.01143	
20	2.713267	0.02810	
21	-1.722634	-0.01708	
22	0.331522	0.00343	
23	-0.496448	-0.00513	
24	2.565923	0.03685	

3. Identifikasi Orde b , r , s Model Fungsi Transfer.

Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift	
NUM1	0.0035274	0.0016240	2.17	0.0302	0	ihsg	0	
Autocorrelation Check of Residuals								
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----				
6	110.05	6	<.0001	-0.370	-0.039	-0.113	0.003	0.004
12	114.09	12	<.0001	-0.016	-0.028	0.010	0.047	-0.047
18	115.62	18	<.0001	-0.019	0.004	0.017	0.015	-0.001
24	125.24	24	<.0001	-0.018	0.051	-0.019	0.031	0.014
30	137.89	30	<.0001	0.062	-0.043	0.086	-0.059	-0.024
36	142.61	36	<.0001	0.025	0.025	-0.061	0.037	0.008
42	148.90	42	<.0001	0.018	-0.041	-0.041	0.068	0.003
48	150.75	48	<.0001	-0.034	0.016	-0.003	-0.003	0.032

4. Model Fungsi Transfer Nilai Transaksi Jual Beli Saham Harian dengan b , r , s (0, 0, 0) dan Deret *noise* ARMA (1,1).

The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift		
MA1,1	0.93088	0.01550	60.05	<.0001	1	zt	0		
AR1,1	0.29178	0.04090	7.13	<.0001	1	zt	0		
NUM1	0.0029976	0.0007315	4.10	<.0001	0	ihsg	0		
Variance Estimate				2.880212					
Std Error Estimate				1.697119					
AIC				2772.866					
SBC				2786.566					
Number of Residuals				711					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.14	4	0.0865	-0.008	0.042	-0.059	0.015	0.033	0.069
12	10.88	10	0.3668	0.012	-0.007	0.020	0.038	-0.039	-0.015
18	13.05	16	0.6693	-0.027	-0.004	0.014	0.009	-0.013	-0.042
24	21.58	22	0.4853	-0.022	0.036	-0.010	0.016	-0.014	-0.036
30	31.64	28	0.2895	0.011	-0.047	0.034	-0.077	-0.059	-0.026
36	34.76	34	0.4316	0.001	0.000	-0.061	0.010	-0.006	-0.019
42	41.44	40	0.4076	-0.017	-0.063	-0.051	0.042	0.001	-0.016
48	43.19	46	0.5308	-0.041	-0.004	-0.010	-0.004	0.019	-0.012
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.808441	Pr < W	<0.0001					
Kolmogorov-Smirnov	D	0.13235	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	4.149654	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	23.86841	Pr > A-Sq	<0.0050					

5. Model Fungsi Transfer Nilai Transaksi Jual Beli Saham Harian dengan b , r , s (0, 0, 0) dan Deret *noise* ARMA (1,1) serta Penambahan *Outlier*.

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Log	Variable	Shift
MA1,1	0.88770	0.02400	36.99	<.0001	1	zt	0
AR1,1	0.31150	0.04794	6.50	<.0001	1	zt	0
NUM1	0.0034051	0.0005774	5.90	<.0001	0	ihsg	0
NUM2	13.21231	0.86775	15.23	<.0001	0	ANUM1	0
NUM3	12.73093	0.86757	14.67	<.0001	0	ANUM2	0
NUM4	11.41634	0.31450	12.48	<.0001	0	ANUM3	0
NUM5	9.20483	0.86723	10.61	<.0001	0	ANUM4	0
NUM6	8.58383	0.91772	9.35	<.0001	0	ANUM5	0
NUM7	8.41826	0.91768	9.17	<.0001	0	ANUM6	0
NUM8	5.96259	0.86732	6.87	<.0001	0	ANUM7	0
NUM9	5.68205	0.86329	6.54	<.0001	0	ANUM8	0
NUM10	6.60085	0.93249	7.08	<.0001	0	ANUM9	0
NUM11	5.79341	0.86754	6.68	<.0001	0	ANUM10	0
NUM12	5.41948	0.87014	6.23	<.0001	0	ANUM11	0
NUM13	5.71620	0.92331	6.19	<.0001	0	ANUM12	0
NUM14	6.02445	0.91480	6.59	<.0001	0	ANUM13	0
NUM15	4.92605	0.86829	5.67	<.0001	0	ANUM14	0
NUM16	5.01228	0.86784	5.78	<.0001	0	ANUM15	0
NUM17	4.60867	0.86831	5.31	<.0001	0	ANUM16	0
NUM18	4.66883	0.87004	5.37	<.0001	0	ANUM17	0
NUM19	4.75003	0.87422	5.43	<.0001	0	ANUM18	0
NUM20	4.80132	0.86962	5.52	<.0001	0	ANUM19	0
NUM21	4.09427	0.86747	4.72	<.0001	0	ANUM20	0
NUM22	3.96544	0.86592	4.57	<.0001	0	ANUM21	0
NUM23	4.02188	0.91985	4.37	<.0001	0	ANUM22	0
NUM24	3.80671	0.91667	4.15	<.0001	0	ANUM23	0
NUM25	3.51554	0.86592	4.06	<.0001	0	ANUM24	0
NUM26	3.17754	0.86732	3.66	0.0003	0	ANUM25	0
NUM27	3.44196	0.86858	3.96	<.0001	0	ANUM26	0
NUM28	3.14217	0.86948	3.61	0.0003	0	ANUM27	0
NUM29	3.07087	0.87022	3.53	0.0004	0	ANUM28	0
NUM30	2.75847	0.86735	3.18	0.0015	0	ANUM29	0
NUM31	-2.28566	0.60780	-3.76	0.0002	0	LSNUM30	0
NUM32	2.75614	0.64623	4.26	<.0001	0	LSNUM31	0
NUM33	4.02748	0.93155	4.32	<.0001	0	ANUM32	0
NUM34	2.82962	0.87283	3.24	0.0012	0	ANUM33	0
NUM35	2.74345	0.86779	3.16	0.0016	0	ANUM34	0
NUM36	-3.55312	0.70405	-5.05	<.0001	0	LSNUM35	0
NUM37	2.99990	0.71041	4.22	<.0001	0	LSNUM36	0
NUM38	2.96710	0.91457	3.24	0.0012	0	ANUM37	0
NUM39	2.72851	0.87461	3.12	0.0019	0	ANUM38	0
NUM40	-2.64479	0.86750	-3.05	0.0024	0	ANUM39	0
NUM41	-1.87903	0.61411	-3.06	0.0023	0	LSNUM40	0
NUM42	3.44963	0.97742	3.53	0.0004	0	ANUM41	0
NUM43	-2.72438	0.59552	-4.57	<.0001	0	ANUM42	0
NUM44	-2.54226	0.86711	-2.93	0.0035	0	ANUM43	0
NUM45	2.35703	0.86919	2.71	0.0069	0	ANUM44	0
Variance Estimate				0.901004			
Std Error Estimate				0.949212			
AIC				1988.986			
SBC				2209.62			
Number of Residuals				711			
* AIC and SBC do not include log determinant.							
Tests for Normality							
Test	--Statistic--		-----p Value-----				
Shapiro-Wilk	W	0.991424	Pr < W	0.0004			
Kolmogorov-Smirnov	D	0.031697	Pr > D	0.0823			
Cramer-von Mises	W-Sq	0.204902	Pr > W-Sq	<0.0050			
Anderson-Darling	A-Sq	1.348175	Pr > A-Sq	<0.0050			

LAMPIRAN E. *Output SAS untuk Pengujian Kehomogenan Varians.*

1. *Output SAS untuk Pengujian Kehomogenan Varians Model ARIMAX (4,1,[5,11]).*

Ordinary Least Squares Estimates					
SSE	0.97883611	DFE	711		
MSE	0.00138	Root MSE	0.03710		
SBC	-2666.3825	AIC	-2666.3825		
MAE	0.02865436	AICC	-2666.3825		
MAPE	100.617386	HQC	-2666.3825		
Durbin-Watson	1.9496	Regress R-Square	0.0000		
		Total R-Square	0.0000		
NOTE: No intercept term is used. R-squares are redefined.					
Tests for ARCH Disturbances Based on OLS Residuals					
Order	Q	Pr > Q	LM	Pr > LM	
1	2.6689	0.1023	2.6120	0.1061	
2	3.4728	0.1762	3.2333	0.1986	
3	3.8971	0.2728	3.5354	0.3162	
4	3.9933	0.4069	3.6881	0.4499	
5	4.0041	0.5488	3.6937	0.5943	
6	11.1229	0.0847	10.6444	0.1000	
7	11.4585	0.1198	11.3742	0.1231	
8	11.4731	0.1763	11.4066	0.1797	
9	11.4808	0.2442	11.4185	0.2481	
10	11.5699	0.3149	11.5877	0.3136	
11	11.5705	0.3968	11.5912	0.3951	
12	13.4541	0.3369	14.3444	0.2793	
GARCH Estimates					
SSE	0.97883611	Observations	711		
MSE	0.00138	Uncond Var	0.001377		
Log Likelihood	1335.4366	Total R-Square	0.0000		
SBC	-2651.1732	AIC	-2664.8732		
MAE	0.02864904	AICC	-2664.8392		
MAPE	100	HQC	-2659.5811		
		Normality Test	28.4879		
		Pr > ChiSq	<.0001		
Parameter Estimates					
Variable	DF	Estimate	Standard Error	t Value	Approx Pr > t
ARCH0	1	0.000600	0.000409	1.47	0.1423
ARCH1	1	0.0635	0.0391	1.62	0.1046
GARCH1	1	0.5009	0.3189	1.57	0.1163

2. *Output SAS untuk Pengujian Kehomogenan Varians Model ARIMAX (0,1,3).*

The AUTOREG Procedure					
Dependent Variable			RESIDUAL		
			Residual: Actual-Forecast		
Ordinary Least Squares Estimates					
SSE	0.90114555	DFE		711	
MSE	0.00127	Root MSE		0.03560	
SBC	-2725.1804	AIC		-2725.1804	
MAE	0.0277243	AICC		-2725.1804	
MAPE	99.9801495	HQC		-2725.1804	
Durbin-Watson	2.0021	Regress R-Square		0.0000	
		Total R-Square		0.0000	
NOTE: No intercept term is used. R-squares are redefined.					
Tests for ARCH Disturbances Based on OLS Residuals					
Order	Q	Pr > Q	LM	Pr > LM	
1	3.0318	0.0816	2.9588	0.0854	
2	4.0247	0.1337	3.7144	0.1561	
3	6.1898	0.1027	6.1666	0.1038	
4	7.1505	0.1281	6.8115	0.1462	
5	8.5590	0.1280	7.6678	0.1755	
6	8.5691	0.1993	7.6678	0.2635	
7	8.6052	0.2823	7.7079	0.3591	
8	8.6139	0.3759	7.7080	0.4625	
9	8.7036	0.4651	7.7751	0.5570	
10	8.7161	0.5592	7.7758	0.6507	
11	8.9667	0.6250	8.1075	0.7036	
12	10.2164	0.5970	9.2491	0.6815	
GARCH Estimates					
SSE	0.90114555	Observations		711	
MSE	0.00127	Uncond Var		0.00127056	
Log Likelihood	1364.91174	Total R-Square		0.0000	
SBC	-2710.1235	AIC		-2723.8235	
MAE	0.02772627	AICC		-2723.7895	
MAPE	100	HQC		-2718.5314	
		Normality Test		9.0506	
		Pr > ChiSq		0.0108	
Parameter Estimates					
Variable	DF	Estimate	Standard Error	t Value	Approx Pr > t
ARCH0	1	0.000959	0.000328	2.93	0.0034
ARCH1	1	0.0930	0.0452	2.06	0.0394
GARCH1	1	0.1520	0.2568	0.59	0.5540

3. *Output SAS untuk Pengujian Kehomogenan Varians Model Fungsi Transfer.*

Ordinary Least Squares Estimates				
SSE	598.266372	DFE		711
MSE	0.84144	Root MSE		0.91730
SBC	1894.98616	AIC		1894.98616
MME	0.71944875	AICC		1894.98616
MAPE	100.86116	HQC		1894.98616
Durbin-Watson	1.9793	Regress R-Square		0.0000
		Total R-Square		0.0000
NOTE: No intercept term is used. R-squares are redefined.				
Tests for ARCH Disturbances Based on OLS Residuals				
Order	Q	Pr > Q	LM	Pr > LM
1	1.7811	0.1820	1.7586	0.1848
2	1.8206	0.4024	1.7796	0.4107
3	2.0732	0.5574	2.0270	0.5668
4	4.2115	0.3781	4.0366	0.4011
5	4.8799	0.4307	4.8577	0.4335
6	4.9262	0.5533	4.9370	0.5519
7	7.5747	0.3716	7.6144	0.3678
8	8.1008	0.4237	7.9196	0.4414
9	8.1131	0.5228	8.0336	0.5308
10	15.4787	0.1156	15.2923	0.1218
11	17.3395	0.0982	17.0870	0.1053
12	19.6022	0.0750	19.8180	0.0706

GARCH Estimates					
SSE	598.266372	Observations		711	
MSE	0.84144	Uncond Var		0.84244046	
Log Likelihood	-346.23146	Total R-Square		0.0000	
SBC	1912.16293	AIC		1898.46292	
MME	0.71931831	AICC		1898.49686	
MAPE	100	HQC		1903.75496	
		Normality Test		15.1938	
		Pr > ChiSq		0.0005	
NOTE: No intercept term is used. R-squares are redefined.					
Parameter Estimates					
Variable	DF	Estimate	Standard Error	t Value	Approx Pr > t
ARCH0	1	0.3856	0.3161	1.22	0.2225
ARCH1	1	0.6592	0.0475	1.25	0.2123
GARCH1	1	0.4831	0.3368	1.22	0.2234

~Halaman ini sengaja dikosongkan~

BIODATA PENULIS



Penulis yang akrab dipanggil salis atau ini merupakan anak bungsu dari dua bersaudara. Lahir di Kabupaten Lamongan pada tanggal 6 Agustus 1992 dari pasangan Bapak Subari dan Ibu Sumiyati Sofyan. Penulis telah menempuh pendidikan formal di TK ABA 1 Sedayulawas (1995-1998), MIM 2 Sedayulawas (1998-2004), SMPN 1 Paciran (2004-2007), dan SMAN 2 Tuban (2007-2010). Penulis diterima di Jurusan Statistika FMIPA

ITS Surabaya pada tahun 2010 dan kemudian melanjutkan kejenjang sarjana dengan NRP. 1313105008. Di tahun kedua perkuliahan, penulis aktif dalam beberapa kepengurusan dan kepanitiaan yang ada di ITS. Kepengurusan yang pernah di emban salah satunya adalah menjadi staff HIMASTA-ITS pada tahun 2011-2012, staff magang BEM ITS di IECC, Kabiرو pengembangan di departemen LITBANG HIMASTA-ITS tahun 2012-2013. Penulis juga aktif dalam kepanitiaan, salah satunya menjadi ketua PPU CAKAHIMASTA-ITS, Seminar Nasional Statistika ITS, PRS 2011, panitia *Rosy Goes to Campus* (Indonesia Bisa), sebagai ATS di ESQ. Besar harapan penulis, penelitian yang telah dikerjakan dapat memberikan manfaat bagi semua pihak, sehingga saran dan kritik yang membangun atau pun diskusi mengenai Tugas Akhir ini dapat disampaikan melalui e-mail tsalisa.m@gmail.com